

الإحصاء والاحتمالات (نظرية وتطبيقات)

تأليف

أ.د. حميد عويّد مشرف العلكه د. عبيد جفين جليغم القحطاني

جامعة الملك سعود





الإحصاء والاحتمالات

(نظرية وتطبيقات)

تأليف

الدكتور عبيد جفين جليغم القحطاني

الأستاذ الدكتور حميد عويد مشرف العكله

جامعة الملك سعود

جامعة الملك سعود

دار جامعة
الملك سعود للنشر
KING SAUD UNIVERSITY PRESS



ص.ب ٦٨٩٥٣ - الرياض ١١٥٣٧ المملكة العربية السعودية

دار جامعة الملك سعود للنشر ، ١٤٤١هـ ، ٢٠١٩م.

ح

فهرسة مكتبة الملك فهد الوطنية أثناء النشر

العلكة ، حميد عويد مشرف

الإحصاء والاحتمالات (نظرية وتطبيقات) / حميد عويد مشرف العلكة ؛ عبيد جفين جليغم القحطاني ،
الرياض ، ١٤٤١هـ

٧٣٦ ص ؛ ٢١ × ٢٨ سم

ردمك : ٩٧٨-٦٠٣-٥٠٧-٨١٢-٢

١- الإحصاء الرياضي ٢- الاحتمالات (رياضيات) أ. القحطاني ، عبيد جفين جليغم (مؤلف
مشارك). ب. العنوان

١٤٤١/٢٣٩٢

ديوي ٥١٢

رقم الإيداع : ١٤٤١/٢٣٩٢

ردمك : ٩٧٨-٦٠٣-٥٠٧-٨١٢-٢

يتقدم المؤلف بالشكر لعمادة البحث العلمي لدعمها هذا الكتاب من خلال برنامج " دعم تأليف كتاب "

صدر هذا الكتاب عن عمادة البحث العلمي ، وقد وافقت العمادة على نشره بعد استيفائه الشروط
العلمية للنشر بالجامعة بخطابها رقم ١٠١٥١٥ / ٤ / ٦٧ / ١٠١٥١٥ وتاريخ ٩ / ٣ / ١٤٣٨ هـ

جميع حقوق النشر محفوظة. لا يسمح بإعادة نشر أي جزء من الكتاب بأي شكل وبأي وسيلة سواء كانت إلكترونية أو
آلية بما في ذلك التصوير والتسجيل أو الإدخال في أي نظام حفظ معلومات أو استعادتها بدون الحصول على موافقة
كتابية من دار جامعة الملك سعود للنشر.

مقدمة المؤلفين

الحمد لله رب العالمين، والصلاة والسلام على نبينا محمد وعلى آله وأصحابه ومن اتبعهم بإحسان إلى يوم الدين. ما من شك في أن الأمم تتقدم بالعلم والمعرفة والعمل الجاد والاجتهاد، وهذا ما أوصانا الله تعالى به، فقد أمرنا سبحانه وتعالى بطلب العلم واستخدامه في اكتشاف ما خلق والبحث والتمحيص في مكوّناتها، حيث يقول ربنا عز وجل في الآية (٣٣) من سورة الرحمن: **يا معشر الجن والإنس إن استطعتم أن تنفذوا من أقطار السماوات والأرض فانفذوا لا تنفذون إلاّ بسلطان***، ولكيلا يتماذى البشر بصنيعهم ومعارفهم ويظنون أنهم قادرون عليها، فقد ذكرنا الله تعالى بقوله في الآية (٨٥) من سورة الإسراء: **وما أوتيتم من العلم إلاّ قليلاً***.

كما هو واضح من عنوان الكتاب فإن العلم الذي سنتناوله هو من العلوم القديمة نسبياً وعلى وجه الخصوص علم الإحصاء. في الحقيقة إن تاريخ **علم الإحصاء** غير محدد تماماً، فليس هناك ما يشير إلى زمن ولادته بشكل دقيق، فالبعض يذكر أنه كان حوالي عام 1662، والبعض الآخر يذكر أنه يعود إلى حوالي عام 1749. لكن في الواقع يُعتقد أن علم الإحصاء قديم قدم تاريخ الحساب عندما بدأت المراحل الأولى للتجمعات البشرية، وبعد الانتهاء من مرحلة المشاع، حيث سادت فيها مظاهر السلطة وحب التملك التي استوجبت العد والتصنيف للممتلكات، والأنعام، والجند، ولذلك يُنظر إلى الإحصاء على أنه توأم الحساب أو ربما كان أحدهما هو الشقيق الأكبر للآخر.

في الواقع إن استخدام تعبير "**الإحصاء**" بين الناس كان متداولاً منذ زمن بعيد جداً وبدلالات واضحة، فعلى سبيل المثال كانت كلمة الإحصاء دارجة في اللغة العربية منذ أكثر من 1500 عام على الأقل ولا أدل على ذلك من ورود كلمة إحصاء في القرآن الكريم في مواضع عديدة (**حيث كانت اللغة العربية في أوج ازدهارها**)، فقد جاءت في القرآن الكريم بمعنى سلوك العد حيث يقول الله تعالى في الآية (١٨) من سورة النحل: **وإن تعدّوا نعمة الله لا تحصوها***، وفي موضع آخر جاء الإحصاء بمعنى تمييز عن مفهوم العد حيث يقول الله تعالى في الآية (٩٤) من سورة مريم: **أحصاهم وعدّهم عدّاً***، فلو كان لكلمة الإحصاء والعد المدلول نفسه لما أتيتا بهذا الترتيب والتأكيد على كلمة العد بعداً. إذن فما هو المقصود بكلمة إحصاهم (**ومنها يمكننا فهم معنى الإحصاء**) هنا إن لم يكن العد؟

إن المقصود هنا (**والله أعلم**) هو معرفة سلوك وخصائص من وقع عليهم العد، وهذا ما سنلمسه بوضوح لدى دراسة الإحصاء كعلم رياضي إذ إننا سنلاحظ أن تعريف علم الإحصاء جاء لينسجم مع ما ذكره الله تعالى في تلك الآيات الكريمة، وأما من حيث شمولية تطبيق هذا العلم، فلا يكاد يخلو قسم من العلوم التطبيقية أو النظرية من دراسة الإحصاء، حيث تتلاقى في هذا النوع من العلوم نتائج من التحليل الرياضي وجبر المنطق والدراسات الاحتمالية لتصبّ جميعاً في تحليل واستقراء مسألة أو ظاهرة يُلَفُّها الشك والارتياب. لقد نُشر أول كتاب في الإحصاء عام 1845 من قبل الرياضي (الانكليزي) Francis Gustavus Paulus Neison وحمل عنوان **مساهمات في الإحصاء الحيوي** "Contributions to Vital Statistics".

لقد نشط في مجال الإحصاء عددٌ كبيرٌ جداً من المهتمين بهذا العلم وأكثرهم من علماء العلوم الطبيعية (الرياضيات، الإحصاء، الفيزياء وعلم الحياة)، وكان من أبرز هؤلاء: بييز Thomas Bayes (1702-1761)، بواسون Siméon Denis Poisson (1781-1840)، بيرسون Karl Pearson (1857-1936) و فيشر Ronald Fisher (1890-1962) وآخرون كثير...

أما علم الاحتمالات فإنه يهتم بدراسة التجارب والظواهر العشوائية ونمذجتها رياضياتياً، وهو الأخ الشقيق الأصغر للإحصاء من عائلة العشوائيات Stochastic (الإحصاء الرياضي ونظرية الاحتمالات)، وتاريخ ولادته حديث (نسبياً) إذا ما قورن بتاريخ ولادة الإحصاء، فعلى الرغم من انتشاره الواسع جداً في أيامنا، فإن مخاض ولادته كان عسيراً، فقد ولد من رحم دور الميسر وحلقات المراهنات، وقد عانى ما عناه من النقد حيناً والرفض كعلم حيناً آخر، فمنهم من رفض قبول الاحتمالات كعلم رياضياتي (كالرياضياتي برتراند Joseph Bertrand (1822 – 1900)، ومنهم من صنف الاحتمالات كفرع من الفيزياء (كالرياضياتي هيلبرت David Hilbert (1862 – 1943).

في الحقيقة نشأ الحساب الاحتمالي من خلال محاولة إيجاد الحلول لبعض ألعاب الحظ، وذكرت كتب التاريخ أن حسابات لبعض ألعاب الحظ (لعبة حجر النرد) نُقلت عبر الحملات الصليبية من المنطقة العربية (من بلاد الشام) التي كانوا يسيطرون عليها، وذلك في القرن الثالث عشر الميلادي، وهذا أقدم ما دون في هذا المجال، وذلك أنه لم يُعثر في كتب التاريخ القديمة (كالهندية والصينية) ما يدل على وجود حسابات لألعاب الحظ، وبعد هذا النقل وجدت حسابات فردية لألعاب الحظ لدى فئة كبيرة من الإيطاليين، ومن أشهرهم كاردانو Gerolamo Cardano (1501-1576). إن القرن السابع عشر حمل في ثناياه تطوراً أكبر وأكثر دقة لحسابات ألعاب الحظ على يد عدد من الرياضياتيين الفرنسيين مثل: باسكال Blaise Pascal (1623-1662)، فيرماط Pierre de Fermat (1607-1665) و هوينغنز Christiaan Huygens (1629-1695) الذي نشر أول كتاب في الحساب الاحتمالي، وكان موسوماً بـ "حسابات لألعاب الحظ" وذلك عام 1657. إلا أن عام 1713 يعد التاريخ الحقيقي لولادة علم الاحتمالات بعد أن تم نشر أول مقالة علمية متقنة للرياضياتي السويسري يعقوب برنولي Jakob Bernoulli (1655-1705)، حيث نُشرت تلك المقالة من قِبَل أخيه يوهان Johann Bernoulli (1667-1748) (بعد ثمان سنوات من وفات يعقوب)، وعلى إثر ذلك حظيت الاحتمالات باهتمام عدد كبير من علماء العلوم الطبيعية عامة، وعلماء الرياضيات خاصة لما لها من تطبيقات مهمة في معظم مجالات العلوم التطبيقية والنظرية على حد سواء. إن النظرية الحديثة للاحتتمالات بدأت من خلال ما يُعرف بـ "مسلمات كلموغوراف" للفضاء الاحتمالي التي وضعت عام 1933 من قبل الرياضياتي الروسي (الاتحاد السوفياتي سابقاً) كلموغوراف Andrey Kolmogorov (1903-1987). بعد ذلك تطورت نظرية الاحتمالات وأصبحت بمثابة الحجر الأساس لمعظم الدراسات المهمة بالتجارب والظواهر العشوائية ونمذجتها.

بما يخص محتوى الكتاب، فقد قدمنا في طياته ثلاثة عشر فصلاً، وثلاثة ملاحق، منها ملحقين في الرياضيات، والثالث للجوال الإحصائية والخصائص العددية المميزة لبعض المتغيرات العشوائية التي ذُكرت في الكتاب، وسرد للمراجع، وثبت للمصطلحات العلمية، ودليل للأعلام الذين وردت أسماؤهم في هذا الكتاب. لقد تناولنا من خلال الفصول المقدمة موضوعات أساس وتطبيقات في الاحتمالات والإحصاء، وقد وزَّعت على ثلاثة محاور رئيسة هي:

١- الاحتمالات، وقد خصص لها الفصول: الرابع، والخامس، والسادس، والسابع والثامن.

٢- الإحصاء، وقد وزَّع على محورين اثنين هما:

أ- الإحصاء الوصفي، وقد خصص له الفصلين: الأول والثاني.

ب- الإحصاء الاستدلالي، وقد خصص له الفصول: التاسع، والعاشر والحادي عشر.

٣- موضوعات متعلقة بالاحتمالات والإحصاء، وقد خصص لها الفصول: الثالث، والثاني عشر، والثالث عشر.

إن توزيعنا لفصول هذا الكتاب على النحو المذكور آنفاً يعود إلى سببين أساسيين هما:

١ - **التدرج المعرفي للمعلومات المقدمة:** بمعنى أننا أخذنا بالحسبان المستوى العلمي والمعرفي للقارئ، ولذلك بدأنا بمعلومات بسيطة متوفرة بعضها لدى القارئ من مرحلة التعليم قبل الجامعي، ومن ثمّ الولوج في الموضوعات الأكثر تجريداً وصعوبةً.

٢ - **الترايط العلمي والموضوعي لل فقرات المقدمة:** فقد حاولنا جاهدين ألاّ تظهر ثغرات بين المعلومات، بمعنى أن المعلومات المتراكبة مبنية على نحو متصاعد، فإذا كان لدينا مفهوم يعتمد على آخر، فقد قمنا (وفي معظم الحالات) بذكر هذا الآخر أولاً ومن ثمّ عرض المفهوم المعني.

في الحقيقة بذلنا جهداً كبيراً لتوضيح الفكر المقدمة بوساطة الأمثلة حيناً والجداول والعروض البيانية حيناً آخر، وعلاوة على ذلك قدمنا بعض التطبيقات باستخدام بعض البرامج الإحصائية وعلى وجه الخصوص برنامج Minitab مستخدمين في ذلك الإصدار السابع عشر.

لقد زحرت فقرات هذا الكتاب وموضوعاته بعدد من الأمثلة المحلولة والتمارين غير المحلولة المناسبة للفكر المقدمة في طياته، وكذلك رُقمت الفقرات، والعلاقات، والجداول، والأشكال بطريقة تُسهّل على القارئ التنقل فيما بينها. كما قمنا باستخدام بعض معاجم الرياضيات من أجل عملية التعريب، وحاولنا جاهدين إغناء موضوعات هذا الكتاب بالقدر المستطاع من المعارف العامة التي تناسب مرحلة الدراسة الجامعية الأولى لمختلف الاختصاصات، ولذلك تجنبنا التخصيص بالقدر المستطاع، وعرضنا النصوص والصيغ بشكل يمكن معه تحويلها ليناسب اختصاص القارئ. هذا بالنسبة لغير الاختصاصيين في الإحصاء والاحتمالات، وأما بالنسبة للمختصين في الإحصاء والاحتمالات فإنّ محتويات هذا الكتاب تناسب (في الحد الأدنى) السنتين الدراسيتين الأوليين من مرحلة الدراسة الجامعية لذوي هذا الاختصاص.

إنّ ما قدّم في طيات هذا الكتاب ليس إلّا غيض من فيض، فكلّ موضوع من الموضوعات المقدمة يمكن تأليف كتب عنها، ولذلك قد يجد القارئ الكثير من الاقتراحات على إضافة فقرة هنا، وحذف أخرى هناك، وتعديل على فقرة في موضع آخر، وهذا أمر قلماً يسلم منه مؤلف مهماً بذل من جهد لأجله، وذلك لأنّه ما زال هناك الكثير، والكثير جداً، من المعلومات التي يمكن أن تضاف في طيات الفصول السابقة، ولكن لكل عمل نهاية، فمن وجد في كتاباتنا نقصاً فإنّ الكمال لله تعالى وحده، ومن وجد خطأً فجلاً من لا يخطئ. لذلك نودّ أن نعرب عن شكرنا وتقديرنا العميقين لكلّ من يبدي لنا ملاحظة مفيدة أو نقداً بناءً حول هذا الكتاب آمليين من الله تعالى أن نكون قد وفقنا في تقديمه بالشكل المناسب والمفيد.

في الختام يودّ المؤلفان تقديم الشكر الجزيل إلى عمادة البحث العلمي في جامعة الملك سعود التي رعت دعم تأليف هذا الكتاب، كما يشكر المؤلفان جامعة الملك سعود التي أسهمت في طباعة هذا الكتاب ونشره.

اللهم انفعنا بما علمتنا وعلمنا ما ينفعنا وزدنا علماً وعملاً متقبلاً إنك أنت السميع العليم

الرياض: يوم الأربعاء في ١٧/١١/١٤٣٨ الموافق لـ ٠٩/٠٨/٢٠١٧

المؤلفان

haloklah@ksu.edu.sa

obalgahtani@ksu.edu.sa

أ.د. حميد عويّد مشرف العكله

د. عبيد جفين جليغم القحطاني

المحتويات

الفصل الأول: البيانات الإحصائية وطرائق عرضها	١
١, ١ تعاريف ومفاهيم أساسية	١
١, ١, ١ علم الإحصاء	١
١, ١, ٢ المجتمع الإحصائي	١
١, ١, ٣ العينة	٢
١, ١, ٤ البيانات الإحصائية	٣
١, ٢ المتغيرات وأنواع البيانات	٥
١, ٢, ١ المتغيرات	٥
١, ٢, ٢ البيانات النوعية	٦
١, ٢, ٣ البيانات الكمية	٩
١, ٣ تمثيل البيانات وعرضها	١١
١, ٣, ١ طريقة الجدول	١٣
١, ٣, ٢ التمثيل باستخدام لوحة الانتشار	١٦
١, ٣, ٣ العرض الشرائطي	١٧
١, ٣, ٤ المضلع	١٩
١, ٣, ٥ الخط المنحني	٢١
١, ٣, ٦ القرص الدائري	٢١
١, ٣, ٧ التمثيل بالصور	٢٣
١, ٤ الجداول التكرارية ذوات الفئات	٢٤
١, ٤, ١ الفئة	٢٤

٢٤	١, ٤, ٢ سعة الفئة
٢٤	١, ٤, ٣ تكرار الفئة
٢٦	١, ٤, ٤ الجداول التكرارية ذوات الفئات المتصلة
٢٦	١, ٤, ٥ الجداول التكرارية ذوات الفئات المتصلة
٢٧	١, ٤, ٦ حساب ساعات الفئات وعددها من أجل جدول تكراري ذي فئات
٣٠	١, ٤, ٧ جداول التوزيع التكرارية
٣٦	١, ٥ العروض البيانية لبيانات جداول التوزيع التكرارية
٣٦	١, ٥, ١ المدرجات التكرارية
٤١	١, ٥, ٢ المضلعات التكرارية
٤٢	١, ٥, ٣ المضلعات التكرارية التراكمية
٤٣	١, ٥, ٤ المنحنيات التكرارية
٤٨	١, ٦ أشكال التوزيعات التكرارية
٤٨	١, ٦, ١ التوزيعات التكرارية المتناظرة
٤٩	١, ٦, ٢ التوزيعات التكرارية الملتوية
٥٠	١, ٦, ٣ تفسير شكل التوزيع
٥١	تمارين الفصل الأول
٥٥	الفصل الثاني: المقاييس الوصفية للبيانات
٥٦	٢, ١ مقاييس النزعة المركزية
٥٦	٢, ١, ١ تعريف مقياس النزعة المركزية
٥٦	٢, ١, ٢ المتوسط
٦١	٢, ١, ٣ المتوسط الموزون
٦٢	٢, ١, ٤ المتوسط الهندسي
٦٤	٢, ١, ٥ المتوسط التوافقي
٦٦	٢, ١, ٦ الوسيط
٧٠	٢, ١, ٧ المنوال
٧٢	٢, ١, ٨ مقارنة بين صفات المتوسط، والوسيط، والمنوال

٧٣.....	٢, ٢ الرِّبَيعِيَّات
٧٣.....	١, ٢, ٢ تعريف الربيعيات
٧٤.....	٢, ٢, ٢ تعيين الربيعيات
٧٧.....	٢, ٣ المئينات
٧٧.....	١, ٣, ٢ تعريف المئيني الرائي (ذو الرقم ٢)
٧٨.....	٢, ٣, ٢ تعيين المئينات
٨٢.....	٢, ٤ مقاييس التشتت
٨٣.....	١, ٤, ٢ الانحراف المتوسط
٨٥.....	٢, ٤, ٢ التباين
٨٩.....	٢, ٤, ٣ قاعدة تشييف التجرية
٩٠.....	٢, ٤, ٤ المدى
٩١.....	٢, ٤, ٥ المدى الربيعي
٩٢.....	٢, ٤, ٦ معامل التغير
٩٣.....	٢, ٤, ٧ معامل التشتت
٩٤.....	٢, ٤, ٨ الدرجة المعيارية Z
٩٥.....	٢, ٤, ٩ الدرجة المعيارية T
٩٦.....	٢, ٥ مقاييس الشكل للتوزيعات التكرارية
٩٦.....	١, ٥, ٢ العزوم المركزية لمجموعة بيانات
٩٩.....	٢, ٥, ٢ مقاييس الالتواء
١٠٥.....	٢, ٥, ٣ مقاييس التفلطح
١٠٧.....	٢, ٦ الأعداد الخمسة والتمثيل الصندوقي للبيانات
٩٦.....	١, ٦, ٢ الأعداد الخمسة لبيانات كمية خام
٩٩.....	٢, ٦, ٢ التمثيل الصندوقي لبيانات كمية خام
١١١.....	تمارين الفصل الثاني
١١٥.....	الفصل الثالث: الارتباط وتحليل الانحدار
١١٥.....	١, ٣ الارتباط الخطي البسيط

١١٥	٣, ١, ١ نماذج من الارتباط
١١٩	٣, ١, ٢ لوحة الانتشار
١٢٢	٣, ١, ٣ التغيرات لمجموعتي بيانات
١٢٧	٣, ١, ٤ معامل بيرسون للارتباط
١٣٠	٣, ١, ٥ معامل سبيرمان لارتباط الرتب
١٤٠	٣, ١, ٦ معامل الاقتران
١٤١	٣, ١, ٧ معامل التوافق
١٤٢	٣, ٢ الانحدار الخطي البسيط
١٤٤	٣, ٢, ١ طريقة المربعات الصغرى
١٤٥	٣, ٢, ٢ معادلتا مستقيما الانحدار لبيانات عينة
١٥٤	٣, ٢, ٣ معادلتا مستقيما الانحدار لبيانات مجتمع إحصائي
١٥٨	٣, ٢, ٤ دقة التقديرات
١٦٥	٣, ٣ الانحدار غير الخطي وتوفيق المنحنيات
١٦٧	٣, ٣, ١ نماذج انحدار يمكن ردها إلى خطية
١٧٠	٣, ٣, ٢ نماذج لا يمكن خطيتها
١٧٠	٣, ٤ الارتباط المتعدد والجزئي
١٧٠	٣, ٤, ١ الارتباط المتعدد
١٧٥	٣, ٤, ٢ العلاقة بين الارتباط المتعدد والارتباط البسيط
١٧٨	٣, ٤, ٣ الارتباط الجزئي
١٨١	٣, ٤, ٤ العلاقة بين الارتباط المتعدد والارتباط الجزئي
١٨٣	تمارين الفصل الثالث
١٨٧	الفصل الرابع: الفضاء الاحتمالي، الاحتمالات الشرطية واستقلال الحوادث
١٨٧	٤, ١ الفضاء الاحتمالي لتجربة عشوائية
١٨٩	٤, ١, ١ تعيين مجموعة نتائج تجربة عشوائية
١٩٥	٤, ١, ٢ جبر الحوادث
٢٠٤	٤, ١, ٣ تعيين الدالة الاحتمالية

٢١٤.....	٤, ١, ٤ خصائص الدوال الاحتمالية.....
٢١٨.....	٤, ٢ الاحتمالات الشرطية.....
٢١٨.....	٤, ٢, ١ الاحتمال الشرطي لحادث.....
٢٢٠.....	٤, ٢, ٢ قانون الضرب في الاحتمالات.....
٢٢٠.....	٤, ٢, ٣ صيغة الاحتمال التام.....
٢٢١.....	٤, ٢, ٤ نظرية بيز.....
٢٢٣.....	٤, ٣ استقلال الحوادث.....
٢٢٣.....	٤, ٣, ١ استقلال حادثين.....
٢٢٤.....	٤, ٣, ٢ استقلال عدد منته من الحوادث.....
٢٢٦.....	٤, ٣, ٣ خصائص الحوادث المستقلة.....
٢٢٩.....	تمارين الفصل الرابع.....
٢٣٣.....	الفصل الخامس: المتغيرات العشوائية وتوزيعاتها الاحتمالية.....
٢٣٣.....	٥, ١ المتغيرات العشوائية.....
٢٣٤.....	٥, ١, ١ تعريف المتغير العشوائي.....
٢٣٨.....	٥, ١, ٢ تعريف العنصر العشوائي.....
٢٣٩.....	٥, ١, ٣ الدالة المميزة لحادث.....
٢٣٩.....	٥, ١, ٤ الدوال في متغيرات عشوائية.....
٢٤٠.....	٥, ٢ قانون ودالة توزيع متغير عشوائي.....
٢٤٠.....	٥, ٢, ١ قانون توزيع متغير عشوائي.....
٢٤٣.....	٥, ٢, ٢ دالة التوزيع لمتغير عشوائي.....
٢٤٤.....	٥, ٢, ٣ الخصائص المميزة لدوال التوزيع الاحتمالية على R
٢٤٨.....	٥, ٢, ٤ الشرط اللازم والكافي لاستمرار دالة توزيع احتمالية على R
٢٥١.....	٥, ٣ تصنيف المتغيرات العشوائية.....
٢٥٢.....	٥, ٣, ١ المتغيرات العشوائية المتقطعة.....
٢٥٨.....	٥, ٣, ٢ المتغيرات العشوائية المستمرة.....
٢٦٥.....	٥, ٤ المتجهات العشوائية وتوزيعاتها الاحتمالية.....

٢٦٦.....	١, ٤, ٥ مفهوم المتّجه العشوائي
٢٦٦.....	٢, ٤, ٥ دالة التوزيع الاحتمالية لمتّجه عشوائي
٢٦٨.....	٣, ٤, ٥ خصائص دوال التوزيع الاحتمالية على \mathbb{R}^n
٢٧٢.....	٤, ٤, ٥ تصنيف المتّجهات العشوائية
٢٧٨.....	٥, ٥ التوزيعات الهامشية
٢٧٨.....	١, ٥, ٥ دوال الكثافة الهامشية
٢٧٩.....	٢, ٥, ٥ دوال التوزيع الهامشية
٢٨٣.....	٦, ٥ التوزيعات الشرطية
٢٨٣.....	١, ٦, ٥ الاحتمالات الشرطية للمتغيّرات العشوائية
٢٨٤.....	٢, ٦, ٥ التوزيعات الشرطية لمتّجه عشوائي متقطّع
٢٨٩.....	٣, ٦, ٥ التوزيعات الشرطية لمتّجه عشوائي مستمر
٢٩٦.....	تمارين الفصل الخامس
٣٠١.....	الفصل السادس: توزيعات احتمالية شهيّة
٣٠١.....	١, ٦ توزيعات احتمالية متقطّعة
٣٠١.....	١, ١, ٦ التوزيع الوحيد النقطة
٣٠٣.....	٢, ١, ٦ التوزيع الثنائي النقطة
٣٠٧.....	٣, ١, ٦ التوزيع المنتظم المتقطّع
٣٠٩.....	٤, ١, ٦ التوزيع الحدّاني
٣١١.....	٥, ١, ٦ التوزيع الحدّاني السالب
٣١٤.....	٦, ١, ٦ التوزيع الهندسي
٣١٨.....	٧, ١, ٦ التوزيع فوق الهندسي
٣٢٠.....	٨, ١, ٦ توزيع بواسون
٣٢٣.....	٢, ٦ توزيعات احتمالية مستمرة
٣٢٣.....	١, ٢, ٦ التوزيع المنتظم المستمر
٣٢٤.....	٢, ٢, ٦ التوزيع الأسّي
٣٢٧.....	٣, ٢, ٦ التوزيع الطبيعي

٣٣٥	٦, ٢, ٤ توزيع ستودنت
٣٣٨	٦, ٢, ٥ توزيع كاي مربع
٣٤٠	٦, ٢, ٦ توزيع فيشر
٣٤٢	٦, ٣ تقارب بعض التوزيعات الاحتمالية من بعضها الآخر
٣٤٢	٦, ٣, ١ مبرهنة (بخصوص تقارب التوزيع فوق الهندسي من الحداني)
٣٤٣	٦, ٣, ٢ مبرهنة (بخصوص تقارب الحداني من البواسوني)
٣٤٣	٦, ٣, ٣ مبرهنة (بخصوص تقارب الحداني السالب من البواسوني)
٢٤٧	تمارين الفصل السادس
٣٥١	الفصل السابع: استقلال وعزوم المتغيرات العشوائية
٣٥١	٧, ١ استقلال المتغيرات العشوائية
٣٥١	٧, ١, ١ الاستقلال لعدد منته من المتغيرات العشوائية
٣٥٦	٧, ١, ٢ الاستقلال لعدد غير منته من المتغيرات العشوائية
٣٥٨	٧, ٢ العزوم للمتغيرات العشوائية
٣٥٨	٧, ٢, ١ العزم الابتدائي من المرتبة k لمتغير عشوائي
٢٧٢	٧, ٢, ٢ العزوم المركزية لمتغير عشوائي
٣٧٦	٧, ٢, ٣ العزم العاملي (الضربي) لمتغير عشوائي
٣٧٦	٧, ٢, ٤ حساب العزوم لبعض المتغيرات العشوائية الشهيرة
٣٨١	٧, ٢, ٥ متباينات شهيرة ذات صلة بالعزوم
٣٨٢	٧, ٢, ٦ معامل الارتباط الخطي لمتغيرين عشوائيين
٣٨٣	٧, ٣ الدوال المولدة الاحتمالية
٣٨٣	٧, ٣, ١ تعريف الدالة المولدة الاحتمالية لمتغير عشوائي
٣٨٤	٧, ٣, ٢ خصائص الدالة المولدة الاحتمالية
٣٨٩	٧, ٣, ٣ الدالة المولدة لعزوم متغير عشوائي
٣٩٢	٧, ٤ الدوال المميزة للتوزيعات الاحتمالية
٣٩٢	٧, ٤, ١ الدالة المميزة لتوزيع احتمالي
٣٩٣	٧, ٤, ٢ خصائص الدالة المميزة لتوزيع احتمالي

٣٩٦.....	٧, ٤, ٣ نظريات شهيرة في دراسة الدوال المميزة
٣٩٨.....	٧, ٥ التوقع الشرطي
٣٩٨.....	٧, ٥, ١ التوقع الشرطي لحادث A بالنسبة إلى تجزئة
٤٠٠.....	٧, ٥, ٢ التوقع الشرطي لمتغير عشوائي بالنسبة إلى تجزئة
٤٠٧.....	تمارين الفصل السابع
٤١١.....	الفصل الثامن: بعض نظريات النهاية المركزية
٤١٢.....	٨, ١ تقارب متتاليات المتغيرات العشوائية
٤١٢.....	٨, ١, ١ أشهر أنواع التقارب لمتتاليات المتغيرات العشوائية
٤١٣.....	٨, ١, ٢ تقارب متتاليات المتغيرات العشوائية
٤١٤.....	٨, ٢ قانون الأعداد الكبيرة
٤١٤.....	٨, ٣, ١ تعريف قانوني الأعداد الكبيرة (الضعيف والقوي)
٤١٥.....	٨, ٣, ٢ مبرهنة بخصوص تقارب المتتالية $\left(\frac{S_n}{n}\right)_{n \in \mathbb{N}}$
٤١٦.....	٨, ٣, ٣ مبرهنة بخصوص تقارب المتتالية $\left(\frac{S_n}{n}\right)_{n \in \mathbb{N}}$ من ثابت حقيقي μ
٤١٧.....	٨, ٣ نظريات النهاية المركزية
٤١٧.....	٨, ٣, ١ مسألة موافير-لابلاس
٤٢١.....	٨, ٣, ٢ مسألة ليندبرغ-ليفلي
٤٢٨.....	٨, ٣, ٣ مسألة ليابانوف
٤٣١.....	٨, ٣, ٤ مسألة ليندبرغ-فيلر
٤٣٤.....	٨, ٣, ٥ مسألة غندينكو
٤٣٧.....	تمارين الفصل الثامن
٤٣٩.....	الفصل التاسع: مدخل إلى نظرية المعاينة
٤٣٩.....	٩, ١ مفاهيم ومصطلحات أساسية
٤٤١.....	٩, ٢ تصنيف العينات
٤٤١.....	٩, ٢, ١ العينات العشوائية

٤٤٧	٩, ٢, ٢ العينات العمدية
٤٤٨	٩, ٣ البناء الرياضي النظري للعينات العشوائية البسيطة
٤٥٠	٩, ٤ النموذج الرياضي النظري لمجتمع إحصائي
٤٥١	٩, ٥ الإحصاءات ودوال توزيع العينات
٤٥١	٩, ٥, ١ الإحصاء
٤٥٣	٩, ٥, ٢ دالة التوزيع العملية للعينات
٤٥٤	٩, ٦ المميزات العددية لبعض الإحصاءات
٤٥٦	٩, ٧ توزيعات المعاينة في حال مجتمع وحيد
٤٥٦	٩, ٧, ١ توزيعات المعاينة لمتوسط وتباين عينة من مجتمع طبيعي
٤٥٩	٩, ٧, ٢ توزيع المعاينة لمتوسط (النسبة) عينة من مجتمع برنولي
٤٦١	٩, ٨ توزيعات المعاينة في حال مجتمعين مستقلين
٤٦٢	٩, ٨, ١ توزيعات المعاينة لفرق متوسطي عينتين ونسبة التباين لعينتين من مجتمعين طبيعيين مستقلين
٤٦٦	٩, ٨, ٢ توزيعات المعاينة للفرق بين متوسطي (نسبتي) عينتين من مجتمعين برنوليين مستقلين
٤٦٧	٩, ٩ الإحصاء الكافية
٤٧١	٩, ١٠ كمية معلومات فيشر التي تُقدمها عينة عشوائية
٤٧٥	تمارين الفصل التاسع
٤٧٧	الفصل العاشر: مدخل إلى نظرية التقدير
٤٧٨	١٠, ١ تعيين مُقدّر معلّمة مجتمع إحصائي
٤٧٨	١٠, ١, ١ طريقة العزوم في تعيين مُقدّرات معالم مجتمع
٤٨٠	١٠, ١, ٢ طريقة الأرجحية العظمى في تعيين مُقدّرات معالم مجتمع
٤٨٥	١٠, ٢ التقدير النقطي
٤٨٦	١٠, ٢, ١ المقدّرات غير المنحازة (أو النصفية)
٤٨٨	١٠, ٢, ٢ المقدّرات المتسقة
٤٨٩	١٠, ٢, ٣ المقدّرات الكفوءة
٤٩٠	١٠, ٢, ٤ متباينة راو كرامر
٤٩٢	١٠, ٣ فترات الثقة

١٠,٣,١	مفهوم فترة الثقة لمعلمة مجتمع إحصائي	٤٩٢
١٠,٣,٢	فترات الثقة لمعلمتي مجتمع طبيعي	٤٩٤
١٠,٣,٣	فترة الثقة لمعلمة مجتمع برنولي	٤٩٨
١٠,٣,٤	فترات الثقة للفرق بين متوسطي مجتمعين طبيعيين مستقلّين ولنسبة تشتتتهما	٥٠١
١٠,٣,٥	فترة الثقة للفرق بين معلمتي مجتمعين برنولين مستقلّين	٥٠٤
٥١٠	تمارين الفصل العاشر	
٥١٣	الفصل الحادي عشر: مدخل إلى اختبارات الفرضيات الإحصائية	
١١,١	مفاهيم أساس في دراسة اختبار الفرضيات الإحصائية	٥١٣
١١,١,١	الفرضيات الإحصائية	٥١٣
١١,١,٢	الأخطاء الناتجة عن دراسة فرضية إحصائية واحتمالاتها	٥١٤
١١,١,٣	تعيين منطقة الرفض المثلّي للفرضية الابتدائية	٥١٩
١١,٢	الاختبارات الإحصائية من أجل معلمتي مجتمع طبيعي	٥٢١
١١,٢,١	اختبارات الإحصائية من أجل متوسط مجتمع طبيعي	٥٢١
١١,٢,٢	اختبارات من أجل تباين مجتمع طبيعي	٥٢٦
١١,٣	الاختبارات الإحصائية من أجل معلمة مجتمع برنولي	٥٢٩
١١,٤	اختبارات من أجل الفرق بين متوسطي مجتمعين طبيعيين مستقلّين	٥٣٠
١١,٥	اختبارات من أجل نسبة التباين لمجتمعين طبيعيين مستقلّين	٥٣٢
١١,٦	اختبار من أجل الفرق بين معلمتي مجتمعين برنولين مستقلّين	٥٣٥
١١,٧	اختبارات إحصائية من أجل فرضيات غير معلّمة	٥٣٦
١١,٧,١	اختبارات جودة توفيق التوزيعات الاحتمالية	٥٣٧
١١,٧,٢	اختبارات إحصائية من أجل تجانس التوزيعات	٥٤٤
١١,٧,٣	اختبار استقلال ظاهرتين (أو متغيّرين)	٥٤٨
١١,٨	تطبيقات	٥٥١
٥٥٩	تمارين الفصل الحادي عشر	

٥٦٣	الفصل الثاني عشر: المتسلسلات الزمنية.....
٥٦٣	١٢, ١ مفاهيم أولية في المتسلسلات الزمنية.....
٥٦٣	١, ١, ١٢ المتسلسلة الزمنية.....
٥٦٤	١, ٢, ١٢ الطوري العشوائي.....
٥٦٥	١, ٣, ١٢ بصمة متسلسلة زمنية.....
٥٦٩	١, ٤, ١٢ مركّبات المتسلسلة الزمنية.....
٥٧٢	١٢, ٢ طريقة التجزئة في تحليل متسلسلة زمنية.....
٥٧٦	١٢, ٣ تحليل الاتجاه العام لمتسلسلة زمنية.....
٥٧٦	١, ١٢, ٣ تقدير الاتجاه العام بوساطة مستقيم.....
٥٧٨	١٢, ٣, ٢ تقدير الاتجاه العام بوساطة كثيرة حدود.....
٥٨٣	١٢, ٣, ٣ تقدير الاتجاه العام بوساطة دوال النمو.....
٥٨٧	١٢, ٣, ٤ اختبار الفرق لـ نوبمان.....
٥٩١	١٢, ٤ دراسة المركّبة الدورية لمتسلسلة زمنية.....
٥٩١	١, ١٢, ٤ طريقة جيب التمام (أو التجيب) لـ هالبرغ.....
٥٩٧	١٢, ٤, ٢ اختبار جودة التوفيق للمركّبة الدورية المقدّرة بوساطة طريقة جيب التمام لـ هالبرغ.....
٦٠١	١٢, ٥ تنعيم المتسلسلات الزمنية.....
٦٠١	١, ١٢, ٥ معامل الخشونة لمتسلسلة زمنية.....
٦٠٢	١٢, ٥, ٢ التنعيم باستخدام المتوسطات المتحركة.....
٦٠٤	١٢, ٦ دراسة التغيّرات الموسميّة لمتسلسلة زمنية.....
٦٠٥	١, ١٢, ٦ طريقة النسبة إلى متوسط متحرك.....
٦٠٨	١٢, ٧ طريقة وينتر لتوليد تنبؤات من متسلسلة زمنية.....
٦٠٩	١, ١٢, ٧ طريقة وينتر في توفيق نموذج متسلسلة زمنية.....
٦١٢	تمارين الفصل الثاني عشر.....
٦١٥	الفصل الثالث عشر: الأرقام القياسية.....
٦١٥	١٣, ١ مفهوم الرقم القياسي.....
٦١٨	١, ١, ١٣ الرقم القياسي.....

٦١٨.....	١٣, ٢ الأرقام القياسية البسيطة
٦١٨.....	١٣, ٢, ١ الرقم القياسي البسيط
٦٢٣.....	١٣, ٢, ٢ الرقم القياسي الكلي البسيط
٦٢٥.....	١٣, ٣ الأرقام القياسية الموزونة
٦٢٥.....	١٣, ٣, ١ مؤشّر لسيريس
٦٢٨.....	١٣, ٣, ٢ مؤشّر باشي
٦٣١.....	١٣, ٣, ٣ المؤشّر المثالي لـ فيشر
٦٣٢.....	١٣, ٤ أمثلة
٦٣٧.....	تمارين الفصل الثالث عشر
٦٤١.....	الملحق A
٦٥٣.....	الملحق B
٦٦٧.....	الملحق C
٦٨٩.....	ملخص لتوزيعات احتمالية شهيرة
٦٩٥.....	المراجع
٦٩٩.....	دليل الأعلام
	ثبت المصطلحات
٧٠٣.....	عربي ⇐ English
٧٢٠.....	عربي ⇒ English

الفصل الأول

البيانات الإحصائية وطرائق عرضها

STATISTICAL DATA AND METHODS OF THEIR PRESENTATION

(١, ١) تعاريف ومفاهيم أساسية

Definitions and Basic Concepts

بادئ ذي بدء نشير إلى أن جميع رموز مجموعات الأعداد التي سترد في هذا الكتاب، وكذلك رموز مُدرّجة وأخرى رياضية، تجدها في بداية الملحق (A).

لقد تحدثنا في مقدمة الكتاب عن تاريخ علم الإحصاء، وذكرنا أنه علم قديم نسبياً وله مدلول واضح عند الكثير من الناس، ولكن وفقاً لمفاهيم العد والتصنيف. أما مدلولاته وفقاً للدراسات العلمية فإنه يحتاج إلى صياغات علمية دقيقة، وهذا ما سنقوم به في كتابنا هذا.

نقدم فيما يلي بعض التعاريف التي لا غنى عنها لدى البدء في دراسة الإحصاء الوصفي، علماً أن المراجع حول مواضيع هذا الفصل الذي يليه كثيرة جداً ومنها ما ذكر في مراجع هذا الكتاب، والاستدلال عليها واضح من عناوين تلك المراجع.

(١, ١, ١) تعريف (علم الإحصاء Statistics)

علم الإحصاء هو أحد فروع الرياضيات الذي يهتم بجمع البيانات ومعالجتها (كالبحث في نوعها وكيفية تقديمها، وكذلك النظر في نواقصها والمفقود منها)، وتمثيلها في جداول وأشكال مناسبة، واستنتاج بعض المقاييس العددية بشأنها، وتحليلها، ومن ثم استقرائها، وأخيراً اتخاذ القرارات المناسبة بشأنها.

أما أهمية هذا العلم فلم تعد تخفى على دارسي العلوم كافة، فيمكننا الجزم بأنه لم يعد هناك فرع من فروع العلوم العلمية (كالفيزياء والكيمياء والطب والهندسات...) والإنسانية (كعلم الاجتماع والآداب والسياسة...) إلا وقد ولج علم الإحصاء في بعض دراساته. في الواقع إن الدراسة الإحصائية لأية مسألة تنطلق مما يُعرف باسم المجتمع الإحصائي الذي يكون الركيزة الأساسية للبيانات التي ستخضع للدراسة، ولذلك لا بد من تقديم تعريف واضح لمعنى المجتمع الإحصائي كي لا يكون هناك أي لبس في ذهن القارئ لهذا المفهوم المهم.

(١, ١, ٢) تعريف (المجتمع الإحصائي Population)

إن أي تجمع لأشياء تجمع بينها صفة مشتركة واحدة على الأقل لتكون محل دراسة لهدف معين تُدعى مجتمعاً إحصائياً (أو مجتمعاً وذلك على سبيل الاختصار)، وأما مكونات المجتمع الإحصائي فإنها تُدعى عناصر أو أفراداً.

فيما يلي نقدم بعض الأمثلة التي توضح هذا المفهوم:

١- في دراسة لتعيين متوسط أعداد الطلاب في المدارس الثانوية في مدينة الرياض، حيث توجد مراحل مختلفة للطلاب مثل الأول، والثاني، والثالث الثانوي، وكذلك يوجد الذكور والإناث، ولكنهم جميعاً تجمع بينهم صفة الدراسة في المرحلة الثانوية، ولذلك نجد أن طلاب المرحلة الثانوية في الرياض يكونون مجتمعاً إحصائياً.

٢- لدى دراسة تطور الحالة المرضية لمرضى في مستشفى ما، حيث يوجد أشخاص كثر وبأنواع مختلفة من الأمراض، ولكنهم جميعاً تربط بينهم صفة الإصابة بمرض، ولذلك مرضى ذلك المستشفى يكونون مجتمعاً إحصائياً.

٣- في دراسة تأثير مضاد حيوي على جراثيم (بكتريا) في مزرعة جرثومية ما، حيث توجد أنواع عديدة منها العنقودية والعصيات و...، ولكن جميعها تندرج تحت اسم الجراثيم، ولذلك الجراثيم الموجودة في هذه المزرعة تكون مجتمعاً إحصائياً.

٤- في دراسة تحديد درجة حلاوة التمور المنتجة من أشجار نخيل التمر في المملكة العربية السعودية، حيث يوجد الكثير من أنواعه مثل: البرحي، المدينة، السكري و...، ولكنها جميعها تنضوي تحت صفة التمر، ولذلك تمر تلك الأشجار تكون مجتمعاً إحصائياً.

٥- في إطار الفحص الدوري للسيارات في مدينة ما، حيث توجد السيارات السياحية والحافلات والشاحنات و...، ولكن جميعها تعرف باسم السيارات لأنها تسير على الأرض بعجلاتها، ولذلك فإن سيارات تلك المدينة تكون مجتمعاً إحصائياً.

٦- لدى تحديد نسبة خام الحديد في فلز الحديد في منجم معين، حيث يمكن أن توجد أنواع عديدة من مركبات الحديد في هذا المنجم مثل: كبريتات الحديد والأكاسيد المختلفة للحديد و...، ولكنها جميعاً تحوي معدن الحديد؛ ولذلك فلز الحديد في هذا المنجم يكون مجتمعاً إحصائياً.

٧- في دراسة تحديد الحالة الفنية لطائرات دول مجلس التعاون الخليجي، حيث توجد فيها الطائرات السفرية والحربية والتدريبية والحوامات و...، ولكنها جميعاً تتصف بقدرتها على الطيران، ولذلك الطائرات الموجودة في دول مجلس التعاون الخليجي تكون مجتمعاً إحصائياً.

نلاحظ من هذه الأمثلة أن المجتمع الإحصائي ليس بالضرورة أن يكون مجتمعاً بشرياً أو حتى مجتمعاً لأحياء، إذ إنه من الممكن أن يكون جماداً أيضاً.

(١، ١، ٢، ١) ملاحظة

إن عدد العناصر المكونة للمجتمع يُدعى **حجم المجتمع** Size of Population، وفي حال كان حجم المجتمع منتهياً فإنه يُرمز لحجمه بحرف لاتيني كبير من قبيل N أو M أو...

(١، ١، ٣) العينة Sample

لقد ذكرنا أن المجتمع الإحصائي يكون الركيزة الأساسية للبيانات التي ستخضع للدراسة، ولكن قد تكون عملية إخضاع جميع عناصر المجتمع للبحث والدراسة (وتُدعى **المسح الشامل** Comprehensive Survey) شاقة جداً، لا بل قد يكون في كثير من الحالات غير ممكن أيضاً، والمثالان الآتيان يوضحان لنا ذلك:

١- بفرض أن باحثاً يريد دراسة سلوك الأسماك البحرية، فإنه لا يمكن لأي عاقل أن يدعي أنه قادر على مسح كافة الأسماك الموجودة في بحار الكرة الأرضية، ولو افترضنا جدلاً أن ذلك ممكن، فتصور الكلفة المادية والزمنية المترتبة على هذه الدراسة.

٢- بفرض أن لجنة الرقابة على الأدوية تريد التحقق من مكونات عقار دوائي معين معبأ في كبسولات (وليكن على سبيل المثال

خافض الحرارة ومسكن الألم 500 mg Setamol)، فعندئذ من غير المجدي والمعقول أن تقوم هذه اللجنة بإخضاع كافة المنتج لتحليل المخبري (ومن ثم إتلاف كافة الإنتاج) للثبوت من أن المنتج يحقق للمواصفات المقدمة من الصانع.

إذن، والحال كذلك كان لا بد من إيجاد وسيلة فعالة نستطيع من خلالها الاستدلال على خصائص المجتمع بتكلفة مادية وزمنية معقولة، وفي الوقت نفسه تجنبنا بعض السلبيات التي ذكرت آنفاً. في هذا الصدد بدت فكرة التعامل مع جزء من المجتمع من أجل تنفيذ الدراسة الإحصائية. إن العلم الذي يبحث في كيفية أخذ هذا الجزء من المجتمع واستخلاص البيانات المطلوبة للدراسة الإحصائية (ومن ثم دراسة خصائصه) يعرف باسم **نظرية المعاينة** Sampling Theory. في الواقع تعدّ نظرية المعاينة جزءاً لا يتجزأ من العلوم الإحصائية المختلفة وخاصة بعد أن أصبح لهذه النظرية أسس رياضية ثابتة ومكانة متميزة في المجالات التطبيقية المختلفة، كما أن تطبيق هذه النظرية في البحوث العلمية تمكننا من الحصول على نتائج سريعة وبكلفة زهيدة نسبياً إذا ما قورنت بكلفة المسح الشامل. ليس هذا فحسب، لا بل إنه في كثير من الحالات ينظر إلى هذه النظرية على أنها الوسيلة الوحيدة في البحث العلمي وذلك للأسباب التي ذكرناها فيما سبق. إن الفقرة الآتية تقدّم لنا تعريف العينة الذي يعدّ بمثابة حجر الأساس لهذه النظرية.

(١، ١، ٣، ١) تعريف (العينة)

يطلق اسم "العينة" على أية مجموعة من العناصر تُسحب من مجتمع إحصائي بغية إخضاعها لدراسة إحصائية معينة ومحددة.

(١، ١، ٣، ٢) ملاحظات

١- يدعى عدد عناصر العينة بـ **حجم العينة** Size of Sample، ويرمز له بحرف لاتيني صغير من قبيل n أو m أو...

٢- نود الإشارة هنا إلى أنه لا يوجد مقياس لتحديد حجم العينة المسحوبة سواء أكان كبيراً أم صغيراً، إذ إن ذلك يتوقف على طبيعة المجتمع المدروس، ونوعية الظاهرة التي هي قيد الدراسة، وكذلك على الإمكانيات المتوفرة لدى الباحث. في الحقيقة ما زال هناك خلاف في تحديد قيمة حجم العينة n الذي من أجله تكون العينة صغيرة الحجم، فهناك مرجعيات تأخذ $n > 30$ والبعض الآخر $n > 28$ وأخرى تعتمد $n > 27$ (ولكن المراجع التي تعتمد هذه الأخيرة قليلة جداً). إن العدد n الذي يحدّد كبر وصغر حجم العينة قابل للتعديل أحياناً حسب طبيعة المسألة المدروسة والإمكانيات المتوفرة لدى الباحث والكلفة المترتبة على دراستها، ولكن سنتفق على أن العينات التي حجمها $n > 32$ هي عينات صغيرة الحجم، وأما العينات التي حجمها $n \leq 32$ فهي عينات كبيرة وسنوضح سبب ذلك لاحقاً عند بناء جداول التوزيع التكرارية.

٣- من يود الاطلاع على المزيد من المعلومات حول العينات وأنواعها وطرائق سحبها يجدها لاحقاً في الفصل التاسع (فصل نظرية المعاينة).

الآن، وبعد إخضاع أفراد المجتمع أو العينة للدراسة الإحصائية ستتولّد لدينا مجموعة من البيانات الإحصائية ندعوها **بيانات** على سبيل الاختصار، ولذلك يمكننا أن نصيغ هذا المفهوم من خلال الفقرة الآتية.

(١، ١، ٤) تعريف (البيانات الإحصائية Statistical Data)

البيانات الإحصائية (وسنستخدم كلمة "بيانات" على سبيل الاختصار لأننا لن نتعامل إلا مع بيانات إحصائية) هي قياسات Measures

أو ملحوظات (أو مشاهدات) Observations تهدف إلى غرض معين في مجتمع إحصائي محدد، ويتم تدوينها نتيجة لـ:

- عملية إنتاجية مثل كميات القمح الناتج عن الزراعة في عام أو أعوام متتالية في بلد ما أو ...
- تجربة معملية مثل حساب أعداد جسيمات ألفا الصادرة عن مادة مشعة خلال فترات زمنية قصيرة (تجارب جايجر-ميرسدن Geiger-Marsden experiments) أو شدة التيار المار في دائرة كهربائية، أو الألوان الناتجة عن تحليل الضوء الأبيض، أو...

- ملاحظات لكائنات موجودة في الطبيعة مثل مراقبة موت الجراثيم (بكتيريا) في مزرعة جرثومية نتيجة لعقار دوائي معين، أو مراقبة ولادة واختفاء النجوم في مجرة من الفضاء الكوني أو ...

(١, ١, ٤, ١) ملاحظات

١- تكون مجموعة بيانات X متقطعة (أو منفصلة) Discrete إذا كانت هذه المجموعة منتهية أو غير منتهية ولكنها قابلة للعد، وأما إذا كانت هذه المجموعة غير منتهية وغير قابلة للعد، فعندئذ يقال عن المجموعة X إنها مستمرة (أو متصلة) Continuous Set (من أجل الاطلاع على مفهوم المجموعة القابلة للعد والمجموعة غير القابلة للعد انظر الملحق A).

٢- إن عملية جمع البيانات لا تتطلب بالضرورة عناصر متخصصة في علم الإحصاء، إذ يكفي لتأدية هذا العمل تأهيل أفراد معينين (كالمعلمين في حالات المسح السكاني)، أو المخبريين الذين يقومون بتنفيذ التجارب في المعامل أو ...

(١, ١, ٤, ٢) أمثلة

١- إن أعداد الأشخاص المهاجرين سنوياً من الأرياف إلى المدن في بلد ما خلال السنوات المتعاقبة تمثل مجموعة متقطعة لبيانات تتعلق بالهجرة الداخلية للبلد (شهدت الفترة 1957-2007) نزوح نحو 800 مليون نسمة من المناطق الريفية إلى المدن - منظمة الفاو FAO (Org. 2007).

٢- أعداد المرضى الذين يتم معالجتهم يومياً في مستشفى تمثل مجموعة متقطعة لبيانات تتعلق بالقدرة الاستيعابية للمستشفى.

٣- تغير مستويات الضغط مع مرور الزمن داخل مرجل بخاري (عال جداً - عال - عادي - منخفض - منخفض جداً) تمثل مجموعة متقطعة لبيانات تُعبر عن تغير الضغط داخل هذا المرجل.


٤- لنأخذ تجربة إلقاء حجر نرد Die (سداسي الوجوه) وقذف قطعة نقود معدنية Coin لمرة واحدة فقط.



فعندئذ سيكون لدينا مجموعة النتائج الممكنة الآتية:

$(H, 1)$	$(H, 2)$	$(H, 3)$	$(H, 4)$	$(H, 5)$	$(H, 6)$
$(T, 1)$	$(T, 2)$	$(T, 3)$	$(T, 4)$	$(T, 5)$	$(T, 6)$

وهي تمثل مجموعة منتهية من البيانات المتعلقة بهذه التجربة، علماً أن الحرف T يشير إلى الشعار (أول حرف من Tails) و H يشير إلى الصورة (أول حرف من Heads)، ومن ثم نلاحظ أن مجموعة البيانات التي حصلنا عليها هي مجموعة متقطعة.



٥- لنأخذ تجربة تغير شدة التيار الكهربائي I المار في مقاومة أومية Resistance R لدى تغير فرق الجهد V على طرفيها، فإن القيم التي سنحصل عليها هي مجموعة مستمرة لبيانات تتعلق بهذه التجربة.

٦- لدى تتبع حالة الطقس في منطقة ما فإن القيم العددية الناتجة عن قياسات أجهزة الرصد كالحرارة والرطوبة والضغط وسرعة الرياح هي بيانات تنتمي إلى مجموعات مستمرة لبيانات تتعلق بحالة الطقس.

٧- لو أخذنا الأرقام الجامعية (ID) لمجموعة من الطلاب (حيث لكل طالب جامعي رقم خاص يميزه عن بقية الطلاب)، فإن هذه الأرقام تكون مجموعة متقطعة لبيانات تتعلق بهؤلاء الطلاب.
إذن، وكما نلاحظ، فإن جميع ما سبق هي حقائق أو مشاهدات أو نتائج لتجارب كما أسلفنا في تعريف البيانات، ولكن السؤال الذي يطرح هنا هو: كيف يمكن لهذه البيانات أن تنتج لدينا، بمعنى ما هي الوسائط التي تولد لنا هذه البيانات؟
إن الإجابة على هذا السؤال تكمن في الفقرة التالية.

(١,٢) المتغيرات وأنواع البيانات

Variables and Classification of Data


نقدم فيما يلي أحد أهم المفاهيم المتعلقة بتوليد البيانات.

(١,٢,١) المتغيرات Variables

في الواقع تنتج البيانات (سواء كانت ناتجة عن قياسات أو استقصاءات) عن وسيلة تُطبق على عناصر العينة (أو المجتمع في حال المسح الشامل) تُدعى **متغيراً** Variable، والأمثلة الآتية توضح لنا جانباً من ذلك.

(١,٢,١,١) أمثلة

١- لنفترض أننا بصدد تنفيذ دراسة لمعرفة متوسط الوزن لمجموعة من الإبل في مزرعة ما، فعندئذ نأتي بميزان مناسب لهذه الغاية، ومن ثم نخضع كل رأس من الإبل يقع عليه الاختيار للوزن فنحصل نتيجة لذلك على مجموعة من الأرقام ولتكن 354 و 347 و 345...، وفي هذه الحالة نلاحظ أن الميزان الذي ولد البيانات قد لعب دور المتغير. لذلك يُقال في مثل هذه الدراسات إن ظاهرة الوزن (أو الوزن على سبيل الاختصار) هي متغير لأنه كلما طبق على رأس من الإبل أعطى قيمة (حقيقية). لاحظ هنا أن هذا المتغير هو تطبيق Map **مجاله** (أو مجموعة تعريفه أو نطاقه) Domain مجموعة الإبل في حين أن **مجاله المقابل** (أو مستقره أو نطاقه المرافق) Co-domain هي فترة من مجموعة الأعداد الحقيقية (من أجل الاطلاع على هذا المفهوم انظر الملحق A).



٢- لنفترض أننا بصدد تنفيذ دراسة لمعرفة أعداد أفراد الأسر لطلاب جامعة الملك سعود، فعندئذ إما أن يُقدم استبيان أو يُسأل الطالب مباشرة أو يُراسل بطريقة ما ليجيب على السؤال المتعلق بهذه الدراسة: **كم عدد أفراد أسرته؟** فنحصل نتيجة لذلك على مجموعة من الأرقام (بيانات) ولتكن 7، 12، 6...، وفي هذه الحالة نلاحظ أن السؤال السابق لعب دور المتغير لأنه كلما طبق على طالب أعطى قيمة (بيان)، وكما هو ملاحظ فإن هذا المتغير هو تطبيق مجاله مجموعة الطلاب، وأما مجاله المقابل فهو مجموعة جزئية من مجموعة الأعداد الطبيعية.

٣- لنفترض أننا بصدد تنفيذ دراسة لمعرفة ألوان العيون في مجتمع بشري ما، فعندئذ نأتي بجهاز لتحديد درجة اللون (أو خبير بتمييز ألوان العيون)، ومن ثم نخضع كل شخص يقع عليه الاختيار للقياس بهذا الجهاز فنحصل نتيجة لذلك على مجموعة من الصفات (بيانات) بني، أسود، أخضر...، وفي هذه الحالة نلاحظ أن جهاز تحديد اللون الذي يولد البيانات الممثلة لظاهرة لون العيون لعب

دور المتغير. لذلك يكون الجهاز الذي حدّد لون العيون هو المتغير، وذلك لأنّه كلما طبّق على شخص أعطى بياناً (صفة أو مسمّى)، وهو تطبيق مجاله مجموعة الأشخاص ومجاله المقابل هي مجموعة الألوان.

٤- لنفترض أنّنا بصدد تنفيذ دراسة تتعلق بتقدير اجتهد الطلاب في مقرر دراسي لدى إحدى الكليات في جامعة الملك سعود (بطريقة المسح الشامل)، فعندئذ نخضع كل طالب في هذه الكلية للاختبار، وبعد عملية التصحيح والرصد نحصل على مجموعة من التقديرات (بيانات) مثل A^+ و B^+ و C^+ و D^+ و F ، وفي هذه الحالة نلاحظ أنّ نموذج الأسئلة الذي قدّم للطلاب لعب دور المتغير. لذلك يُقال في مثل هذه الدراسات إنّ نموذج الأسئلة هو المتغير لأنّه كلما طبّق على طالب أعطى بياناً (رمزاً)، وهو تطبيق مجاله مجموعة الطلاب ومجاله المقابل مجموعة التقديرات.

أما عن سبب تسميتها متغيرات فإنّ ذلك يعود إلى نتائج تطبيقها على العناصر، فكلما طبّق على عنصر أعطى نتيجة قد تختلف من عنصر إلى آخر، إذ إنّ تلك القيم ليست بالضرورة أن تكون متساوية أو متماثلة، وإن كانت متساوية أو متماثلة فلا ضير من ذلك، وبناءً على ما سبق نلاحظ أنّه من منطلق رياضيّاتي أنّ المتغير هو تطبيق (يمثّل وسيلة أو سمة) مجاله مجموعة عناصر العينة (أو المجتمع في حال المسح الشامل) ويأخذ قيمه في مجموعة ذات طبيعة ما، ولذلك يمكننا أن نصيغ مفهوم المتغير كما في التعريف الآتي.

(١, ٢, ١, ٢) تعريف (المتغير)

المتغير هو تطبيق يمثّل وسيلة أو سمة (أو أي مولّد للبيانات) مجاله العينة (أو المجتمع في حال المسح الشامل) ويأخذ قيمة في مجموعة ذات طبيعة ما (قد تكون عددية أو غير ذلك).

إذا كانت مجموعة قيم المتغير قابلة للعدّ على الأكثر فعندئذ يُقال عنه أنّه متغير متقطع Discrete Variable، وأما إذا كانت مجموعة قيم المتغير غير قابلة للعدّ فعندئذ يُقال عنه أنّه متغير مستمر Continuous Variable.

لقد لاحظنا أنّ تطبيق المتغيرات على عناصر العينة أو المجتمع يولّد لنا البيانات، وهذه البيانات ليست من ذات الطبيعة (أو من النوع نفسه)، فلو أمعنا النظر في طبيعة البيانات التي حصلنا عليها في الأمثلة السابقة نجد أنّها ليست من طبيعة واحدة، فمنها ما هو رقمي ناتج عن قياس، والآخر وصفي (رمزي أو اسمي، وقد يكون رقمياً ولكنه غير ناتج عن قياس) وقد تكون مزيجاً. في الواقع يمكن أن تكون البيانات المصنّفة إما كمية أو نوعية على أبعد حد، وذلك لأنّ البيانات التي من النوع المزيج تندرج تحت اسم البيانات النوعية أيضاً. لذلك سنقوم فيما يلي بتقديم تصنيف البيانات بغية تسهيل دراستها.

(١, ٢, ٢) تعريف (البيانات النوعية Qualitative Data)

البيانات النوعية (أو البيانات الوصفية) هي تلك البيانات التي تنتج عن التساؤل بـ "ما" أو "كيف".

تتكون البيانات النوعية عادةً من:

١- أسماء مثل: صورة وشعار في رمي قطعة النقود.

٢- صفات مثل: بني، أسود، أزرق، وأخضر في دراسة لون العيون.

٣- أرقام لها دور الصفات مثل: الأرقام الجامعية (ID) للطلاب في جامعة ما.

بكلمات أخرى. إنّ البيانات النوعية تتكوّن بشكل أساسي من تسميات Labels أو أسماء Names أو أرقام مستخدمة لتحديد سمة كل عنصر من العينة أو المجتمع، وغالباً ما يُشار إليها بـ **البيانات الفتوية**، كأن يُقال مثلاً: فئة الأشخاص ذوي العيون السوداء، أو فئة ذوي الدخل المحدود، فلو رجعنا إلى الأمثلة (١, ٢, ٤, ١) السابقة فإنّنا نجد بيانات الفقرات ٣، ٤ و ٧ هي بيانات نوعية، وكذلك الفقرتين ٣ و ٤ / من الأمثلة (١, ٢, ١, ١) هي بيانات نوعية أيضاً، والمزيد من الأمثلة حول البيانات النوعية تقدّمها لنا الفقرة الآتية.

(١, ٢, ٢, ١) أمثلة

١- الجنسية لمجموعة من الأشخاص المقيمين في بلد ما يُولد بيانات من قبيل: آسيوي، أوروبي، أمريكي، أسترالي و...، وهي بيانات نوعية لأنها مسميات لها دور الصفات. لاحظ هنا أن هذا النوع من البيانات لا يقبل صفة الترتيب، والترتيب الذي وردت به لا يعني أكثر من وجود لمثل هذه الجنسيات فقط.

٢- الحالة الصحية لمرضى في مستشفى تولد بيانات من قبيل: ممتازة (متماثل للشفاء)، جيدة جداً (في تحسن مستمر)، جيدة (وضعه مستقر ولا توجد لديه مضاعفات)، مقبولة (في وضع غير مستقر)، سيئة (وضعه غير مستقر ولديه مضاعفات)، وهي تقديرات لها صفة البيانات النوعية. لاحظ هنا أن هذا النوع من البيانات يقبل صفة الترتيب فيما بينها، والترتيب الذي وردت به له معنى.

٣- الحالة الاجتماعية لأفراد مجتمع بشري يُولد بيانات من قبيل: عازب، متزوج، مطلق وأرمل، وهي مسميات أو صفات، ومن ثم فهي جميعاً بيانات نوعية. لاحظ هنا أن هذا النوع من البيانات لا يقبل صفة الترتيب، والترتيب الذي وردت به لا يعني أكثر من وجود لمثل هذه الحالات في المجتمع البشري.

٤- حالة الطقس في منطقة ما من الأرض يُولد بيانات من قبيل: صحو، غائم، ماطر، مثلج، مغبر و...، وهي مسميات أو صفات، ومن ثم فهي جميعاً بيانات نوعية. لاحظ هنا أن هذا النوع من البيانات لا يقبل صفة الترتيب أيضاً، والترتيب التي وردت به لا يعني أكثر من وجود مثل هذه الحالات في المناخ فقط.

(١, ٢, ٢, ٢) ملاحظات

١- إن المتغيرات التي تولد بيانات نوعية تُدعى **متغيرات نوعية** Qualitative Variables، ومن ثم تكون المتغيرات التي وردت في الفقرات /٣، ٤ و /٧ من الأمثلة (١، ١، ٤، ٢) وكذلك الفقرتين /٣ و /٤ من الأمثلة (١، ٢، ١، ١) وجميع فقرات المثال (١، ٢، ٢، ١)، هي متغيرات نوعية متقطعة (باستثناء المتغير المُولد لبيانات المثال /٣ من (١، ٢، ١، ١) يمكن له أن يكون مستمراً)، ونشير هنا إلى أن مجموعة قيم هذه المتغيرات قد تكون غير قابلة للعد (كما في طيف الضوء المرئي).

٢- يمكن تصنيف البيانات النوعية وفقاً لمقاييس رئيسية عديدة هي:

أ- المقياس الاسمي Nominal Scale

إن البيانات النوعية التي تنطوي تحت هذا النوع من المقاييس تكون غير قابلة للترتيب فيما بينها، وكذلك تكون التصنيفات في هذا النوع من القياسات مختلفة وغير متكررة وليس لها أية دلالات عددية تقبل الحساب، وإن كانت البيانات من النوع الرقمي فهي لتسهيل التعامل مع التصنيفات ولا تُعطى لها إمكانية للترتيب، فعلى سبيل المثال:

أ-١- لو أخذنا البيانات الناتجة عن قذف قطعة نقد معدنية لمرة واحدة فقط حيث لدينا H (صورة) و T (شعار)، فنلاحظ أنه ليس لدينا ما يفضل إحداها على الأخرى في الترتيب.

أ-٢- لو أخذنا البيانات الناتجة عن دراسة لون العيون عند البشر حيث لدينا بني، أسود، أزرق و...، فنلاحظ هنا أنه ليس لدينا ما يفضل لون على آخر في الترتيب.

أ-٣- لو أخذنا المهام الموكلة إلى أعضاء فريق كرة قدم حيث لدينا المهاجم (ولنفترض أن رقمه 10)، الجناح الأيمن (ولنفترض أن رقمه 17)، الجناح الأيسر (ولنفترض أن رقمه 15)، الدفاع (ولنفترض أن رقمه 22) وحارس المرمى (ولنفترض أن رقمه 1)، فعندئذ لا يمكننا القول إن اللاعب رقم 10 أكثر مهارة من اللاعب رقم 1، أو أن اللاعب رقم 22 أكثر مهارة من اللاعب رقم 15، فلكل لاعب من هؤلاء مهارات وفنون لعب ومهام تختلف عن الآخر، ومن ثم عملية الترتيب بين الأرقام هنا ليست ذات معنى.

أ-٤- لو أخذنا البيانات الناتجة عن تحديد الحالة الاجتماعية (عازب، متزوج، مطلق، أرمل) لمجتمع حي من أحياء مدينة ما، أو

البيانات الناتجة عن تحديد حالة الجنس لمجموعة نباتات في غابة (مذكر، مؤنث، خنثى)، فإننا نجد لها بيانات نوعية تفتقر إلى خاصية الترتيب فيما بينها أيضاً.

ب- المقياس الترتيبي Ordinal Scale

إنّ البيانات النوعية التي تنطوي تحت هذا النوع من المقاييس تكون قابلة للترتيب فيما بينها وفقاً لمعيار محدد وواضح، كأن تكون من الأقوى إلى الأضعف أو من الأعلى إلى الأدنى أو...، فعلى سبيل المثال:

ب-١- لنفترض أننا بصدد دراسة قساوة المعادن، وأخذنا مجموعة من المعادن مكونة من الحديد، والنحاس، والألماس، والذهب، والرصاص، وأردنا أن نعين أيها أكثر قسوة من الآخر (باستخدام الخدش فيما بينها، وقد وضع هذا المقياس عام 1812 م على يد عالم المعادن الألماني موس Mohs)، فنجد أنّ الألماس يأتي في الترتيب الأول ويليه الحديد، فالنحاس، ومن ثمّ الذهب وأخيراً الرصاص، فنلاحظ أنّ هذه البيانات النوعية (الألماس، والحديد، والنحاس، والذهب، والرصاص) أمكن ترتيبها وفقاً لمعيار القساوة.

ب-٢- لو أخذنا نظام تقدير نتائج الاختبارات في الجامعات السعودية وهي $A^+, B^+, C^+, D^+, A, B, C, D$ و F فنجد أنّ هذه البيانات النوعية لها ترتيب تنازلي $A^+, A, B^+, B, C^+, C, D^+, D$ و F التي تعني أنّ الطالب الذي حصل على تقدير B (أي أنّه حصل على درجة x مع $80 \leq x \leq 84$) أقل من التقدير السابق له B^+ (الحاصل على درجة x مع $85 \leq x \leq 89$).

ب-٣- لو أخذنا استبياناً مقدّماً للطلاب من أجل دراسة إحصائية تخص المحاضرين حيث يُطلب من الطالب الإجابة على مجموعة من الأسئلة بإحدى العبارات المدونة في الجدول الآتي:

المعيار	أوافق بشدة	أوافق	محايد	لا أوافق	لا أوافق مطلقاً
:	:	:	:	:	:

فلاحظ أنّ البيانات الناتجة عن هذا الاستبيان (أوافق بشدة، أوافق، محايد، لا أوافق ولا أوافق مطلقاً)، هي بيانات نوعية تقبل الترتيب إلّا أنّ المشكلة في تفسير نتائج تحليلها تكمن في عدم وضوح التباعد بين هذه البيانات، فمن الممكن أن يجيب طالب بعبارة "لا أوافق" وآخر يستخدم عبارة "لا أوافق مطلقاً" على معيار ما، وعندما نستفسر منهما كلّ على انفراد ما يعنيه بإجابته نجد لدهما التصور نفسه حول الإجابة على هذا المعيار، بمعنى أنّ كلاّ منهما استخدم بعداً خاصاً به لفهم عبارة "لا أوافق" و "لا أوافق مطلقاً". لذلك يُفضل في مثل هذه الحالات استخدام تقييمات رقمية لتحديد التباعد بين كلّ تقييم وآخر.

ب-٤- بالرجوع إلى الفقرة ٣/ من الأمثلة (٢، ٤، ١، ١) فإننا نجد أنّ البيانات الناتجة عن تحديد مستوى الضغط في المرجل هي بيانات ترتيبية، وإذا كان معيار الترتيب من الأعلى ضغطاً إلى الأقل فيكون لدينا الترتيب الآتي لتلك البيانات: عال جداً - عال - عادي - منخفض - منخفض جداً، وهكذا نجد أنّ هذه البيانات تتبع المقياس الترتيبي.

ب-٥- لو أخذنا الأرقام الجامعية لطلاب إحدى كليات جامعة ما، فعندئذ نلاحظ أنّ هذه البيانات النوعية يمكن ترتيبها وفقاً لتسلسل قيم الأعداد من الأكبر إلى الأصغر أو بالعكس، ولكن قد يكون هذا الترتيب غير ذي معنى إذا بدأت من الصفر ولفصل محدد (وتكون البيانات في هذه الحالة اسمية). لكن يمكن أن تصبح ذات معنى إذا ما حوت الأرقام على ما يدل على عام التسجيل للطلاب مثلاً كما هو الحال لدى طلاب جامعة الملك سعود حيث خصّصت الخانات الثلاث اليسرى من الرقم الجامعي لتشير إلى العام الذي سجّل فيه الطالب في الجامعة، فعلى سبيل المثال نجد أرقاماً من النماذج 433...، 434...، 435...، 436...، وفي هذه الحالة يمكننا ترتيب البيانات في مجموعات وفقاً لعام التسجيل، ولكنّها ضمن المجموعة السنوية الواحدة هي بيانات اسمية وليست ترتيبية.

(١, ٢, ٣) تعريف (البيانات الكمية Quantitative Data)

البيانات الكمية هي بيانات تتكون من أرقام تمثل قيماً عددية تنتج عن التساؤل بـ "كم".

غالباً ما تكون البيانات الكمية ناتجة عن قياسات أو إحصاءات أو تعدادات، ومن كونها قيماً عددية فإن العمليات الحسابية العادية ذات مغزى عند التعامل مع هذا النوع من البيانات.

لاحظ أن الفقرات / ١، ٢، ٥ و / ٦ من الأمثلة (١-٤-٢) وكذلك الفقرتين / ١ و / ٢ من الأمثلة (١-٢-١-١) تُقدم لنا بيانات كمية.

(١, ٢, ٣, ١) ملاحظات

١- إن المتغيرات التي تولد بيانات كمية تدعى **متغيرات كمية** Quantitative Variables، ومن ثم تكون المتغيرات الواردة في الفقرات / ١ و ٢ و ٥ و / ٦ من الأمثلة (١، ٢، ١، ١) وكذلك الفقرتين / ١ و / ٢ من الأمثلة (١، ٢، ١، ١) هي متغيرات كمية.

٢- بناءً على ما سبق بخصوص قدرة مجموعة قيم متغير، فإن المتغيرات الواردة في الفقرتين / ٥ و / ٦ من الأمثلة (١، ٢، ١، ١) وكذلك الفقرة / ١ من الأمثلة (١، ٢، ١، ١) هي متغيرات مستمرة، في حين أن المتغيرات الواردة في الفقرتين / ١ و / ٢ من الأمثلة (١، ٢، ١، ١) وكذلك الفقرة / ٢ من الأمثلة (١، ٢، ١، ١) هي متغيرات متقطعة.

٣- يمكن تصنيف البيانات الكمية في مقياسين رئيسيين أيضاً هما:

أ- مقياس الفترة Interval Scale

هذا النوع من المقاييس استمد اسمه من كون البيانات التي تتبعه تنتمي لفترة من مجموعة الأعداد الحقيقية، وله خصائص أخرى كالمحافظة على خاصية الترتيب للبيانات، بمعنى أنه يمكن ترتيبها؛ وذلك لأن العلاقة (\leq) هي علاقة ترتيب جزئي على مجموعة الأعداد الحقيقية R ولكن من أجل هذا النوع من البيانات لا معنى لعملية نسبية الكميات بعضها إلى بعض، وكذلك لا تعتمد قيمة الصفر كنقطة بداية له إن وجدت (بمعنى أن الصفر هنا لا يعني العدم). إذاً يمكننا أن نميز مقياس الفترة بالخصائص الآتية:

أ-١- قيمته تنتمي إلى فترة من R (قيم البيانات الناتجة عن هذا المقياس تنتمي لمجموعة غير قابلة للعد).

أ-٢- يمكن ترتيب قيم البيان.

أ-٣- يمكن قياس درجة الاختلاف بين البيانات، ولكن دون إمكانية استخدام النسبة فيما بينها، بمعنى أن عملية نسبية الكميات بعضها إلى بعض غير ذي معنى أو ليس له دلالة واضحة.

أ-٤- قيمة الصفر في هذا النوع من البيانات لا تعني العدم أو عدم امتلاك أي شيء (انظر الأمثلة الآتية)، بمعنى أن هذا النوع من البيانات لا يعتمد الصفر كنقطة بداية (أو نقطة أصل).

ب- مقياس النسبة Ration Scale:

لقد سمي هذا المقياس بهذا الاسم لأنه تقدير نسبة بين كمية وأخرى من النوع نفسه، وعلاوة على ذلك فإن هذا المقياس يحافظ على جميع الخصائص التي يتمتع بها مقياس الفترة، ويزيد على ذلك أنه من الممكن التعامل مع بيانات لها قيم متقطعة أيضاً، وأخيراً من مميزاته الفارقة عن المقاييس الأخرى أن قيمة الصفر هنا إن وجدت فلها معنى واضح وتعتمد كنقطة بداية (أو نقطة أصل).

إذاً يمكننا تمييز مقياس النسبة بامتلاكه لخصائص مقياس الفترة مضافاً إليها الخصائص الآتية:

ب-١ - قيم البيانات قد تنتمي إلى فترة (مجموعة مستمرة) أو إلى مجموعة قابلة للعد على الأكثر.

ب-٢ - من الممكن نسبة الكميات بعضها إلى بعض، وعملية النسبة هذه لها معنى.

ب-٣ - يعتمد الصفر كنقطة بداية، وهذا يعني أن قيمة الصفر إن وجدت لها معنى واضح (قيمة الصفر قد تعني العدم).

(٢، ٣، ٢، ١) أمثلة

١ - المتغير الذي يرصد الزمن اللازم لإنهاء كتابة واجب منزلي من قبل طالب (مقدراً بالدقيقة) هو متغير كمي مستمر تبدأ قيمه بعدد موجب تماماً وتمتد إلى فترة محدودة فتصبح مجموعة قيمه من الشكل $(0, \alpha]$ ، والصفر هنا غير موجود؛ لأنه يعني أن الطالب لم يبدأ بكتابة الواجب أصلاً. من جهة أخرى يمكننا هنا نسبة الكميات بعضها إلى بعض كأن نقول: إن الزمن اللازم لكي ينهي طالب كتابة واجبه المنزلي لمقرر الرياضيات يساوي ضعف الزمن اللازم لكي ينهي ذلك الطالب كتابة واجبه المنزلي لمقرر الإحصاء، ومن ثمّ البيانات التي نحصل عليها من هذا المتغير تتبع مقياس النسبة.

٢ - المتغير الذي يرصد عدد العاطلين عن العمل في مدينة ما خلال أشهر متعاقبة هو متغير كمي متقطع قد تبدأ قيمه من الصفر وتمتد إلى أعداد صحيحة غير سالبة ولكنها محدودة، فتصبح مجموعة قيمه من الشكل 0 و 1 و 2 و ... و n علماً أن n عدد صحيح محدود. من جهة أخرى يمكننا هنا نسبة الكميات بعضها إلى بعض، كأن نقول إن عدد العاطلين عن العمل في شهر شباط (فبراير) من هذا العام يساوي نصف عدد العاطلين عن العمل في شهر شباط من هذا العام الماضي. أخيراً نجد أن للصفر هنا معنى واضح، فإذا كان عدد العاطلين عن العمل في شهر شباط من هذا العام يساوي 0 فهذا يعني أنه لم يعد لدينا عاطلون عن العمل في هذا الشهر، ومن ثمّ البيانات التي نحصل عليها من هذا المتغير تتبع مقياس النسبة أيضاً.

٣ - المتغير الذي يرصد درجة حرارة الطقس في منطقة معينة من الأرض خلال الأيام المتعاقبة من عام معين مقدرة بالدرجة المئوية Celsius ويرمز لها بـ $^{\circ}\text{C}$ ، أو الفهرنهايت Fahrenheit ويرمز لها بـ $^{\circ}\text{F}$ علماً أن $^{\circ}\text{F} = 1.8(^{\circ}\text{C}) + 32$ هو متغير كمي مستمر، والقيم التي نحصل عليها قد تمتد من القيمة السالبة -60 درجة مئوية (كما يحصل في شرق كازاخستان حيث تمّ تسجيل -60 درجة مئوية) وحتى +71 درجة مئوية (حيث سجل أحد الأقمار الاصطناعية +71 درجة مئوية في صحراء لوط بإيران)، وهنا نلاحظ أن الصفر لا يعني أنه لا توجد حرارة وإنما الطقس بارد إلى حد درجة تجمد الماء، ومن ثمّ لا ينظر إلى درجة الصفر على أنها نقطة بدء وإنما درجة يمكن بلوغها. من جهة أخرى لا يمكننا نسبة هذه المقادير بعضها إلى بعض، فمن غير الجائز أن نقول إن درجة حرارة منطقة A تساوي ضعف درجة حرارة منطقة أخرى B، وإنما يمكننا القول إن الفرق بين درجتَي الحرارة للمنطقتين يساوي x مثلاً. فعلى سبيل المثال إذا كانت درجة الحرارة في المنطقة A تساوي 0 درجة مئوية (وهي تعني أن هذه المدينة باردة نسبياً) وكانت درجة الحرارة في المنطقة B تساوي 20 درجة مئوية (وهي تعني أن هذه المدينة دافئة نسبياً)، فعندئذ لا نستطيع القول إن المنطقة B أدفأ عشرين مرة من المدينة A ولا القول إن المنطقة A أبرد عشرين مرة من المنطقة B، وكل ما يمكننا قوله هو إن الفرق بين درجتَي الحرارة للمنطقتين يساوي 20 درجة مئوية. إذاً درجة الحرارة في هذا المثال هي من النوع الفتراتي، ومن ثمّ البيانات التي نحصل عليها من هذا المتغير تتبع مقياس الفترة.

٤ - المتغير الذي يرصد درجة الحرارة لغاز مثالي مقدرة بـ الكلفن Kelvin (ويرمز لها بـ K)، علماً أن $K = ^{\circ}\text{C} + 273.15$ هو متغير كمي مستمر، وقيمه قد تمتد من 0 كلفن (تدعى الدرجة $K=0$ بالصفر المطلق، وهي ما تزال في إطار درجات الحرارة النظرية التي لم يتم الوصول إليها بعد) إلى أي قيمة موجبة أخرى ولكنها محدودة. فإذا ما وصلت درجة حرارة الغاز المثالي إلى الصفر كلفن فحينئذ ينعدم الضغط لهذا الغاز، والصفر هنا هو نقطة بدء للقياس، ومن ثمّ البيانات التي نحصل عليها من هذا المتغير تتبع مقياس النسبة.

٥- المتغير الذي يرصد المسافة بين مدينة A وأخرى B هو متغير مستمر، ويأخذ قيمه في فترة $(0, \alpha]$ مع α عدد حقيقي محدود. والصفر هنا غير موجود بسبب التمايز بين المدينتين فرضاً، وفي حال وجوده يكون له معنى، فإذا كانت المسافة تساوي الصفر فإن ذلك يعني أن المدينة A هي B نفسها. كذلك نلاحظ أنه يمكننا تنفيذ عملية النسبة على المسافات بين المدن، كأن نقول إن البعد بين المدينة A و B يساوي ضعف المسافة بين A و C، وبذلك تصبح البيانات التي نحصل عليها من هذا المتغير تتبع مقياس النسبة.

٦- المتغير الذي يرصد أوزان صناديق تحوي أناناس، ومفترضين أن وزن الصندوق الذي سيحتوي هذه الفاكهة مهماً بالمقارنة مع وزن حبة الأناناس (بمعنى أن دقة الميزان لن تظهر وزناً للصندوق الفارغ)، فنجد أن مقياس أوزان هذه الصناديق هو متغير مستمر ويأخذ قيمه في فترة $(0, \alpha]$ مع α عدد حقيقي محدود، والصفر هنا يعني أن الصندوق وجد فارغاً. كذلك نلاحظ أنه يمكننا تنفيذ عملية النسبة على هذه الصناديق حيث يمكننا القول إن وزن الصندوق رقم 3 يساوي مرة ونصف من وزن الصندوق ذي الرقم 5 مثلاً، وهكذا نلاحظ أن البيانات الناتجة عن هذه الأوزان تتبع مقياس النسبة. لكن يجب الانتباه عند التعامل مع متغير الوزن، وذلك لأن الصفر مرتبط بدقة الجهاز الذي يقيس الوزن حيث نعلم أنه لا يوجد شيء على الأرض ليس له وزن بسبب جاذبية الأرض، فعلى سبيل المثال لو قمنا بوزن الصندوق باستخدام ميزان دقته غرام واحد فإننا على الأرجح لن نحصل على الصفر حتى لو كان الصندوق فارغاً، في حين أننا لو قمنا بوزنه في ميزان آخر دقته 1000 كغ (طن) فإن الميزان سوف يشير إلى قيمة الصفر حتى وإن كان الصندوق مليئاً بالأناناس. بالطبع هذه حالات للمناقشة فقط، وأما في الجانب التطبيقي فإنه يستخدم من أجل كل دراسة مقياساً أو معياراً مناسباً للدراسة الإحصائية المطلوبة.

(١, ٢, ٣, ٣) ملاحظات

١- نشير هنا إلى أن الطول، العرض، الارتفاع والعمق هي حالات خاصة من مفهوم المسافة، ويعاملان معاملة المسافة التي سبق وصفها.

٢- يمكن رد البيانات النوعية إلى بيانات كمية من خلال إعطاء قيمة عددية تميز الاسم أو الصفة التي ولدت البيان النوعي الناتج عن التجربة أو الدراسة، كأن نعطي في الدراسة المتعلقة بمستوى الضغط في مرجل بخاري القيم 5، 4، 3، 2 و 1 عوضاً عن مرتفع جداً، مرتفع، عادي، منخفض جداً على الترتيب، أو أن نعطي في الدراسة المتعلقة بقذف قطعة نقود معدنية القيم 0 و 1 عوضاً عن H و T، ولكن على ألا نخضع هذه البيانات الأخيرة للعمليات الحسابية التي تطبق على البيانات الكمية. لذلك ستكون دراساتها القادمة مركزة على البيانات الكمية، وهذا التخصيص لا يقلل من شأن وعمومية هذه الدراسة.

(١, ٣) تمثيل البيانات وعرضها

:Representation and Graphing of Data

بعد إتمام جمع البيانات تأتي مرحلة البحث في كيفية التعامل مع هذه البيانات، إذ إنه يتم التحقق أولاً من اكتمال عدد البيانات، فإذا كانت هناك بعض البيانات المفقودة فحينئذ يجب النظر في كيفية تحصيلها ثانية أو تقديرها، علماً أن عملية التقدير للبيانات المفقودة تقع خارج إطار هذا الكتاب ولذلك لن نتطرق إلى عملية تقدير البيانات المفقودة. إن البيانات التي نحصل عليها تكون عادة على أشكال مختلفة، فمنها على شكل قيم عددية مفردة، وبعضها الآخر يعرض تغير ظاهرة ما مع مرور الزمن أو مع مسميات كالبلدان، أو المدن، أو مع كليهما معاً، ومجموعات البيانات الآتية توضح لنا بعضاً من هذه النماذج، حيث سنستشهد بها بين الحين والآخر.

مجموعة البيانات (٣, ١. أ) (بيانات عينة على شكل قيم عددية مفردة):

تمثل البيانات الآتية أعمار 64 بطارية جهاز حاسب محمول من نوع محدد (مقدرة بالشهر):

2	11	4	13	15	12	4	13	12	17	5	13	11	15	12	5	12	5	13
6	12	11	6	12	6	6	12	7	15	12	7	13	11	13	7	7	12	7
9	11	12	9	11	9	15	12	9	11	9	12	9	11	9	15	17	19	17
11	11	13	13	15	13	15												

مجموعة البيانات (٣, ١. ب) (بيانات عينة على شكل قيم عددية مرتبطة بالزمن):

لتكن لدينا البيانات الآتية لعدد الحجيج من خارج المملكة العربية السعودية منذ عام 1423 وحتى عام 1432 هـ (مأخوذة عن موقع الإحصاءات العامة في المملكة العربية السعودية):

الجدول (١, ١)

العام	عدد الحجيج من خارج المملكة العربية السعودية	العام	عدد الحجيج من خارج المملكة العربية السعودية
1423	1431012	1428	1707814
1424	1419706	1429	1729841
1425	1534769	1430	1613965
1426	1557447	1431	1799601
1427	1654407	1432	1828195

مجموعة البيانات (٣, ١. ج) (بيانات مجتمع على شكل قيم عددية مرتبطة بمسميات):

لتكن لدينا البيانات الآتية التي تبين لنا عدد سكان مناطق المملكة العربية السعودية (المصدر: وزارة الاقتصاد والتخطيط، مصلحة الإحصاءات العامة).

الجدول (١, ٢)

المنطقة	تعداد السكان لعام 2010	المنطقة	تعداد السكان لعام 2010
منطقة مكة المكرمة	6915006	منطقة تبوك	791535
منطقة الرياض	6777146	منطقة حائل	597144
المنطقة الشرقية	4105780	منطقة نجران	505652
منطقة عسير	1913392	منطقة الجوف	440009
منطقة المدينة المنورة	1777933	منطقة الباحة	411888
منطقة جازان	1365110	منطقة الحدود الشمالية	320524
منطقة القصيم	1215858	-----	-----

إن مجموعات البيانات السابقة تُعرف باسم **البيانات الخام** Raw Data، والدراسة هنا تتركز بشكل أساسي على قيم وسلوك البيانات وليس على المسميات، ودور المسميات هنا للاستدلال بها والمقارنة فيما بينها، وأما الأزمنة فقد تكون من باب الاستدلال بها أو أن يكون لها دور مهم في الدراسة الإحصائية كما هو الحال في المتسلسلات الزمنية (انظر الفصل الثاني عشر).
الآن بفرض أن جميع البيانات المطلوبة جمعت دون نقصان، فإن كانت البيانات قليلة (وهنا عبارتي قليل وكثير تخضع لإمكانات

الباحث وتقديراته، فهي عبارات نسبية) فحينئذ يمكن استنتاج بعض التصورات حول سلوك هذه البيانات بالملاحظة، ومن ثمّ يمكن للمرء الانتقال للتعامل مع المقاييس العددية للبيانات (سنأتي على ذكرها لاحقاً في الفصل الثاني) لاستنباط بعض المميزات العددية لهذه البيانات. أما إذا كان عدد البيانات كبيراً فعندئذ عملية عرض جميع هذه البيانات واحدة فواحدة قد يكون مجهداً أو غير مجدزماً أو مادياً، ولذلك يقوم المرء عادةً بعرض هذه البيانات وفق شكل يسمح له بأخذ انطباع أولي سريع عن هذه البيانات بأقل جهد ممكن، ولهذا السبب ابتكرت طرائق عديدة لعرض البيانات الإحصائية. إنّ هذه الطرائق تتمايز بعضها عن البعض الآخر من حيث المبدأ والمنهج المعتمد في إنشائها، فمنها ما يُقدّم البيانات في جداول رقمية ومنها ما يعرضها على شكل شرائط عمودية أو أفقية والآخر على شكل خطوط منكسرة أو منحنية و...، ولتوضيح ذلك سنقوم بشرح موجز لبعض الطرائق المستخدمة في عرض البيانات الإحصائية.

(١, ٣, ١) طريقة الجدول Table Method

إنّ طريقة الجدول لعرض البيانات تتلخص في أن يقوم المرء بتحميل (أو صبّ) البيانات التي لديه في جدول بتقسيمات معينة حسب متطلبات المسألة المدروسة، وذلك بغية أخذ انطباع سريع عن سلوك البيانات وتسهيل العمليات الحسابية المتعلقة بها، فعلى سبيل المثال نجد أنّ مجموعتي البيانات رقم (١, ٣. ب) و (١, ٣. ج) السابقتين مقدّمة جدولياً، وأما من أجل البيانات الخام رقم (١, ٣. أ) فيمكن عرضها في جدول بحيث يتم تدوين القيم في عمود، وفي العمود الآخر تدوّن التكرارات المقابلة لتلك القيم (عدد المرات التي تتكرر فيها تلك القيم)، وهذا النوع من الجداول الناتجة يدعى **جدولاً تكرارياً بسيطاً** (أو جدولاً تكرارياً وذلك على سبيل التبسيط والاختصار)، ويلجأ عادةً إلى هذا النوع من الجداول عندما يكون عدد البيانات الخام كبيراً. في الحقيقة توجد نماذج مختلفة من العرض الجدولي للبيانات ومنها:

(١, ٣, ١) الجداول التكرارية Frequency Tables


إنّ الجداول التكرارية تستخدم بكثرة في التجارب المعملية ووسائل الإعلام لسهولة بنائها وفهمها من قبل الكثير من الأشخاص، ويُنسب الجدول التكراري من خلال صبّ البيانات الخام في جدول بحيث يتم تدوين قيم الممثلين للبيانات في عمود (أو صف) (فعلى سبيل المثال في الجدول الآتي لدينا القيمة $x_3 = 5$ ممثّل لكل البيانات التي لها القيمة 5)، وفي العمود الآخر (أو الصف الآخر) تدوّن التكرارات المقابلة لقيم ممثلي البيانات (في الجدول الآتي نجد لممثّل القيمة 5 تكرار يساوي 3، وهذا يعني أنّه لدينا ثلاثة بيانات لها القيمة 5)، ومن ثمّ يمكن عرض مجموعة البيانات (١, ٣. أ) المُعطاة في جدول تكراري وفقاً للعرض الآتي:

الجدول (١, ٣) خاص بمجموعة البيانات (١, ٣. أ)

التكرار (عدد البطاريات)	عمر البطارية (بالشهر)	i	التكرار (عدد البطاريات)	عمر البطارية (بالشهر)	i
f_i Frequency of x_i	x_i		f_i Frequency of x_i	x_i	
10	11	7	1	2	1
12	12	8	2	4	2
9	13	9	3	5	3
7	15	10	4	6	4
3	17	11	5	7	5
1	19	12	7	9	6
64	-----	----	-----	-----	Total

(١, ٣, ١, ٢) جدول الساق والأوراق Stem and Leaf Table

توجد طريقة أخرى لصب البيانات الخام في جدول مشابه للجدول التكرارية تُدعى **عرض الساق والأوراق**، والغاية منها تصنيف البيانات في مجموعات جزئية، كأن نبين القيم ما بين 10 و19 في مجموعة جزئية واحدة، والقيم ما بين 20 و29 في مجموعة جزئية ثانية، والقيم ما بين 70 و79 في مجموعة جزئية أخيرة، وقد يعتمد أسلوب آخر للتصنيف ولكن وفقاً لهذه الآلية. بمعنى آخر، إنَّ جدول الساق والأوراق هو عرض جدولي توضيحي يبين تكرار حدوث قيم معينة، ويتم ذلك من خلال صب البيانات الخام في جدول بعمودين أحدهما يُخصّص للساق Stem والآخر للأوراق Leaf، وذلك على النحو الآتي:



بفرض أنه لدينا بيانات على شكل أعداد صحيحة مكونة من خانتين على الأكثر (كما في المثال الآتي وذلك على سبيل التبسيط في الشرح)، فعندئذ نضع في عمود الساق القيمة 0، وفي العمود المقابل لها (عمود الأوراق) نضع جميع القيم المكونة من خانة واحدة فقط، وبعد ذلك نتقل إلى الأرقام المكونة من خانتين فنبدأ بالقيم التي خانة العشرات لها هي الأصغر، فنضع العدد المكون لخانة العشرات في عمود الساق وأما الأجزاء الأخرى المكونة لخانة الآحاد من العدد فنضعها في عمود الأوراق، فإذا ما انتهينا من هذه نتقل للرقم الأكبر والمكون من خانتين أيضاً وهكذا دواليك حتى الانتهاء من عملية الصب، ويفضل عادة ترتيب الأوراق تصاعدياً.

(١, ٢, ١, ٣, ١) مثال

لتكن البيانات الآتية التي تعرض عدد ساعات العمل اليومية لحاسب مركزي في مؤسسة تعليمية:

15 3 14 13 14 11 21 5 14 19 9 21 20 6 8 22 23 23 7

عندئذ لصب هذه البيانات في جدول الساق والأوراق سنقوم أولاً بوضع صفر إلى يسار الأعداد التي أصغر من عشرة (وذلك على سبيل التبسيط)، فيصبح للبيانات المعطاة العرض الآتي:

15 03 14 13 14 11 21 05 14 19 09 21 20 06 08 22 23 23 07

ولدى صب البيانات المعطاة في جدول نحصل على الجدول الآتي.

الجدول (٤, ١, أ) الأوراق بحسب موضعها في البيانات المقدمة

الساق Stem	الأوراق Leafs	التكرار Frequency
0	3, 5, 9, 6, 8, 7	6
1	5, 4, 3, 4, 1, 4, 9	7
2	1, 0, 2, 2, 3, 3	6
Total	-----	19

الجدول (٤, ١.ب) الأوراق مرتبة تصاعدياً

الساق Stem	الأوراق Leafs	التكرار Frequency
0	3, 5, 6, 7, 8, 9	6
1	1, 3, 4, 4, 4, 5, 9	7
2	0, 1, 2, 2, 3, 3	6
Total	-----	19

الآن، وفي حال كانت البيانات مكونة من أعداد غير صحيحة (جزء صحيح وآخر عشري)، فعندئذ نضع في عمود الساق أصغر قيمة صحيحة مع قيمة الجزء العشري الأصغر قيمة، وفي العمود المقابل لها (عمود الأوراق) نضع جميع القيم المتبقية والمكونة للجزء العشري بعد الرقم الذي دون في عمود الساق. بعد ذلك ننتقل إلى الأرقام المكونة القسم الصحيح نفسه (إن وجد) ولكن بجزء عشري أول أكبر من سابقه ونجري على هذه الأرقام التصنيف نفسه الذي تم على الأرقام السابقة، فإن انتهينا من الأجزاء العشرية ننتقل للجزء الصحيح الأكبر من السابق، وهكذا دواليك حتى الانتهاء من عملية الصب، والمثال الآتي يوضح لنا ذلك.

(٢, ٢, ١, ٣, ١) مثال

لتكن البيانات الآتية التي تعرض أوزان عشرين حبة قرع في مزرعة (مقدرة بالكيلو غرام):

0.14 0.13 0.12 1 1.01 1.05 1.11 1.12 1.3 1.3 1.3 1.32 1.39
1.34 1.44 2.23 2.29 2.24 2.2 3.19 3.15 3.12 3.17 3.60 3

فعندئذ لصب هذه البيانات في جدول الساق والأوراق يُفضل (وعلى سبيل التبسيط) القيام أولاً بإضافة صفرين بعد الفاصلة إلى يمين كل عدد صحيح (كأن نكتب 1 بالشكل 1.00)، وصفر بعد الرقم العشري الأول بعد الفاصلة للأرقام ذات المرتبة العشرية الواحدة (كأن نكتب 1.3 بالشكل 1.30)، وذلك لجعل المراتب العشرية متماثلة، فيصبح للبيانات المعطاة العرض الآتي (نشير هنا إلى أنه في بعض الأحيان يقدم الجدول بعد ترتيب بيانات الأوراق تصاعدياً أيضاً):

الجدول (٥, ١)

الساق Stem	الأوراق Leafs	الأوراق بعد ترتيبها تصاعدياً Leafs	التكرار Frequency
0.1	3, 4, 2	2, 3, 4	3
1.0	1, 0, 5	0, 1, 5	3
1.1	1, 2	1, 2	2
1.3	0, 0, 0, 2, 9, 4	0, 0, 0, 2, 4, 9	6
1.4	4	4	1
2.2	9, 3, 4, 0	0, 3, 4, 9	4
3.0	0	0	1
3.1	9, 5, 2, 7	2, 5, 7, 9	4
3.6	0	0	1
Total	-----	-----	25

كما يوجد نوع آخر من التمثيلات الجدولية للبيانات يسمى جدول التوزيع التكراري حيث سنأتي على شرحه لاحقاً في هذا الفصل.

Bar Graph العرض الشرائطي (١, ٣, ٣)


تقوم طريقة العرض الشرائطي للبيانات على تمثيل البيانات من خلال شرائط مستطيلة رأسية أو أفقية (وفي العروض ثلاثية الأبعاد قد تستخدم نماذج أخرى كالأعمدة الأسطوانية أيضاً) منفصلة بعضها عن بعض، وتتلخص هذه الطريقة بوضع المسميات أو الزمن أفقياً أو رأسياً ومن ثم رسم شريط مستطيل (عمودياً إذا كان رأسياً أو شريطاً إذا كان أفقياً) على كل مسمى (أو كل سنة أو كل فترة زمنية) بحيث يكون طول كل شريط ممثلاً للقيمة (أو التكرار) المقابل لذلك المسمى (أو لتلك السنة أو الفترة الزمنية) وذلك باستعمال مقياس رسم مناسب، وتستخدم هذه الطريقة للمقارنة بين قيم الظواهر حسب المسميات أو الزمن، أو لمقارنة ظواهر بعضها مع بعض.

أمثلة (١, ٣, ٣, ١)

١- البيانات الآتية تمثل تقديرات 50 طالباً في مقرر الإحصاء:

F	C	D	C	A	B	C	F	D	D
C	D	C	C	D	A	B	C	D	B
D	C	F	D	C	B	B	A	D	C
B	D	C	B	B	C	B	C	D	C
B	A	D	C	B	D	C	D	B	F

فنجند العرض الشرائطي الأفقي والرأسي لهذه البيانات كما في الشكلين الآتين:




الشكل (٤, ١ ب) العرض بالشرائط الرأسية (بالأعمدة).




الشكل (٤, ١ أ) العرض بالشرائط الأفقية.

٢- بالعودة إلى مجموعة البيانات (١, ٣ أ) نجد أن عرضها الشرائطي الشكل الآتي مستخدمين الأعمدة في ذلك:




الشكل (٥, ١)

٣- بالعودة إلى مجموعة البيانات (٣, ١. ب) نجد أن عرضها الشرائطي الشكل الآتي مستخدمين الأعمدة في ذلك:



الشكل (١, ٦) أعداد الحجاج من خارج المملكة.

٤- بالعودة إلى مجموعة البيانات (٣, ١. ج) نجد أن عرضها الشرائطي الشكل الآتي مستخدمين في ذلك الأشرطة الأفقية
 لاحظ هنا أنه قد يكون التمثيل بالأشرطة الأفقية أكثر ملاءمة من الأشرطة الرأسية لوجود مسميات):



الشكل (١, ٧) تعداد السكان لمناطق المملكة العربية السعودية.


(١, ٣, ٣, ٢) ملاحظات

١- من الممكن أن يكون لدينا ممثلين (كالمسميات مثلاً) للبيانات ويقابها قيم موجبة وأخرى سالبة (مثل درجات الحرارة)، فعندئذ سيكون لدينا عروضاً شرائطية تتجه باتجاهين متضادين حيث تدعى أمثال هذه العروض بـ **العروض الشرائطية ثنائية الاتجاه**.


٢- يمكن تقديم العروض الشرائطية لمجموعتين أو أكثر من البيانات بآن واحد (في عرض واحد) وذلك لجعل المقارنة بين العروض البيانية أكثر يسراً وسهولة، ومن هذه العروض:

أ- **طريقة الشرائط المتجاورة** Contiguous Bar Charts، وتستخدم هذه الطريقة أسلوباً مماثلاً تماماً للتمثيل الشرائطي من أجل كل مجموعة بيانات على حدة، وبعد ذلك توضع الأشرطة الممثلة للشيء الواحد قريبة أو ملاصق بعضها لبعض، ويميز أحدهما

عن الآخر بالتلوين المختلف أو التظليل المختلف، والشكل الآتي يقدم لنا نموذج لهذا العرض:




ب- طريقة الشرائط المترتبة Overlapped Bar Charts، وتستخدم هذه الطريقة أسلوباً مماثلاً تماماً للتمثيل الشرائطي من أجل كل مجموعة بيانات على حدة أيضاً، ولكن توضع الأشرطة الممثلة للشيء الواحد بعضها فوق بعض، ويميز أحدهما عن الآخر بالتلوين المختلف أو التظليل المختلف، والشكل الآتي يقدم لنا نموذجاً لهذا العرض (المصدر مصلحة الإحصاءات العامة والمعلومات، الحسابات القومية 1431-1432 هـ، 2010 م):



(١,٣,٤) المضلع Polygon


- تستخدم هذه الطريقة في عرض تغير ظاهرة (أو عدة ظواهر) مع الزمن أو مسمى لشيء ما، ومن الأمثلة على ذلك:
- تغير درجة الحرارة في مدينة ما مع مرور الزمن.
 - تغير نسبة السكر في نبات الشمندر السكري لدى أنواع مختلفة منه.
 - تغير الطول لأنواع مختلفة من المعادن لدى تعرضها لدرجة حرارة معينة.

إنَّ التمثيل بخطوط مستقيمة متتالية تكوّن بمجمّلها خطاً منكسراً يتم برسم محورين متعامدين، ومن ثمّ رصد قيم الظاهرة كنقاط ذات إحداثيين بحيث يُمثّل المحور الإحداثي OX الزمن أو المسمّيات في حين يُمثّل المحور الإحداثي OY قيم المتغير، وبعد تمثيل كل القيم بنقاط نقوم بوصل كل نقطتين متتاليتين بقطعة مستقيمة فنحصل بذلك على خط منكسر يُمثّل تغيّر الظاهرة المدروسة مع الزمن (أو المسمّيات أو...)، وهذا التمثيل يدعى **مضلّعاً**، فعلى سبيل المثال لو أردنا عرض البيانات (٣، ١.٠) بوساطة المضلّع (أو الخطوط المنكسرة) فإننا نجد لها التمثيل البياني الآتي:




الشكل (١, ١٠)

وأما البيانات (٣، ١.٠) فنجد لها المضلّع الآتي:



الشكل (١, ١١)

وأخيراً نجد العرض الآتي للبيانات (٣، ١.٠) لدى استخدام المضلّع:



الشكل (١, ١٢)


(١, ٣, ٥) الخط المنحني Curve:

إنَّ هذه الطريقة تماثل طريقة العرض باستخدام المضلَّعات (الخطوط المنكسرة) حيث نحصل عليه بتمهيد الخط المنكسر ليصبح منحنياً من خلال إحدى الطرائق الآتية:


١- جعل الفترات التي تبني عليها هذه الخطوط المنكسرة قصيرة جداً مع زيادة عددها بشكل كبير جداً، ولذلك فإنَّ هذه الطريقة نادرة الاستخدام في المجالات التطبيقية.

٢- نقوم بالتمهيد اليدوي للخطوط المستقيمة لتصبح منحنية وملائمة عند مرورها بالنقاط الممثلة للبيانات، وهذه الطريقة قليلة الاستخدام أيضاً لأنها تحتاج إلى مهارات في الرسم.

٣- استخدام أحد البرامج في عملية التمهيد كأن نستخدم عملية التمهيد الشرائحي Spline من الدرجة الثانية أو الثالثة (متوفرة في برنامج Curve Expert) أيهما أنسب للعرض وأقل تناقضاً مع واقع البيانات، وهذه الطريقة تعطينا نتائج ممتازة لعملية التمهيد، فعلى سبيل المثال لو أردنا عرض البيانات (١, ٣) من خلال التمهيد الشرائحي من الدرجة الثانية والثالثة فنجد لها التمثيلين البيانيين الآتين على الترتيب:



الشكل (١, ٣). تمهيد شرائحي من الدرجة الثانية.



الشكل (١, ٣). تمهيد شرائحي من الدرجة الثالثة.

فلاحظ أنَّ المنحنى الناتج عن التمهيد الشرائحي من الدرجة الثالثة أكثر ملائمةً لواقع البيانات، ولكن هذا لا يعني أنَّ رفع درجة التمهيد الشرائحي ستعطينا نتائج أفضل دوماً.

(١, ٣, ٦) القرص الدائري Pie Chart


إنَّ تمثيل الرسوم البيانية باستخدام القرص شائع بكثرة وخاصة في وسائل الإعلام، وهي تُعطي صورة مفيدة عن قيم النسبة المئوية، وخاصة عند مقارنة مجموعات مختلفة من البيانات، إلا أنَّ رسمها أكثر صعوبة من الحالات السابقة إذ تحتاج إلى فرجار ومنقلة، أو استخدام البرامج الإحصائية (وهي متوفرة لدى معظم البرامج الإحصائية). على أي حال، يلجأ إلى استعمال هذه الطريقة عندما نكون

بحاجة لتقسيم الكل إلى k من الأجزاء، وأما لرسمها فإننا نقوم أولاً برسم دائرة بنصف قطر مُثبت (غالباً يكون عمودياً) يُعدّ مبدأً لقياس الزاوية عنه، ثم نحسب الزوايا α_i (مقدّرة بالدرجات Degrees) وتأخذ إلى يمين العمود السابق باتجاه دوران عقارب الساعة، وبحيث يكون للجزء i قطاع دائري زاويته تُحسب بوساطة العلاقة الآتية:

$$\alpha_i := \frac{n_i}{n} \times 360 \text{ for a sample with size } n \quad [1,1]$$

$$\alpha_i := \frac{n_i}{N} \times 360 \text{ for a population with size } N \quad [1,2]$$

علماً أنّ n_i هو عدد العناصر (أو البيانات) التابعة للجزء i مع $i \in \mathbb{N}_k$ ، فعلى سبيل المثال لو أردنا عرض البيانات (١, ٣, ١٠) من خلال تجزئة القرص (حيث لدينا حجم العينة $n = 64$)، فإننا نجد التمثيل البياني لتلك البيانات له الشكل الآتي (١, ١٤)، علماً أنّ قيمة زاوية القطاع الدائري الأول (الموافق للقيمة 2) تساوي:




الشكل (١, ١٤)

$$\alpha_1 = \frac{n_1}{n} \times 360 = \frac{1}{64} \times 360 = 5.63 = 5 : 37 : 48$$

الدرجات degrees
↓
الجزء العشري من الدرجة
الدقائق
الثواني

في حين نجد أنّ قيمة زاوية القطاع الدائري السادس (الموافق للقيمة 9) تساوي:

$$\alpha_6 = \frac{n_6}{n} \times 360 = \frac{7}{64} \times 360 = 39.38 = 39 : 22 : 48$$




الشكل (١, ١٥)

أما إذا أردنا عرض البيانات ١, ٣, ١٠ ب/ من خلال تجزئة القرص (حيث لدينا حجم العينة $n = 16276757$)، فإننا نجد لها التمثيل البياني المقدم في الشكل الجانبي (١, ١٥)، حيث لدينا قيمة زاوية القطاع الدائري الأول (الموافق للعام 1423) والسادس (الموافق للعام 1428) تساويان:

$$\alpha_1 = \frac{n_1}{n} \times 360 = \frac{1431012}{16276757} \times 360 = 31.65 = 31 : 39 : 00$$

$$\alpha_6 = \frac{n_6}{n} \times 360 = \frac{1707814}{16276757} \times 360 = 37.77 = 37 : 46 : 12$$

أخيراً إذا أردنا عرض البيانات (١, ٣, ١٠ ج) باستخدام تجزئة القرص (حيث لدينا حجم المجتمع $N = 27136977$)، فإننا نجد تمثيلها البياني في الشكل الآتي (١, ١٦)، علماً أنّ قيمة الزاوية للقطاع الدائري الأول (الموافق لمنطقة الرياض) والسادس (الموافق لمنطقة الجوف) تساويان:



الشكل (١, ١٦)

$$\alpha_1 = \frac{n_1}{N} \times 360 = \frac{6777146}{27136977} \times 360 = 89.91 = 89 : 54 ; 36$$

$$\alpha_6 = \frac{n_6}{N} \times 360 = \frac{440009}{27136977} \times 360 = 5.84 = 5 : 50 ; 24$$

(١, ٣, ٧) التمثيل بالصور (الطريقة التصويرية) Representation by Picture

في هذه الطريقة تستخدم صورة لتمثيل الشيء الخاضع للدراسة، ومن ثمَّ عرض هذه الصورة عدداً من المرات يساوي التكرار للقيمة المقابلة، وهذه الطريقة شائعة الاستخدام في وسائط الإعلام كالصحف والمجلات، فعلى سبيل المثال لو أردنا عرض البيانات (١, ٣) وفقاً للطريقة التصويرية فإننا سنجد لتمثيلها التصويري العرض الآتي:

الجدول (١, ٦)

عمر البطارية بالشهر	يرمز لبطارية واحدة 
2	
4	 
5	  
6	   
7	    
9	     
11	      
12	       
13	      
15	    
17	  
19	
sum	64



مثال آخر: لنفترض أنه لدينا في مدينة ما 6500 سيارة، وأردنا أن نعبر عن ذلك بالطريقة التصويرية، فإنه يرسم شكل سيارة لكل 1000 سيارة فينتج لدينا العرض الجانبي لعدد السيارات المعطى.

(١,٤) الجداول التكرارية ذوات الفئات

Classes Tables

في هذا النوع من الجداول يكون الاهتمام منصباً على عدد من الفئات (وهي عبارة عن فترات ذات طول موجب تماماً) بحيث يكون لكل منها سعة تساوي طول الفترة التي تمثلها. إن القيم المفردة للبيانات لا تكون موضع اهتمام في هذا النوع من الدراسة، ولذلك يُقال عن هذه البيانات إنها **بيانات مجمعة** (أو **بيانات مجمدة**) Grouped Data لأنه يتم تجميعها في جدول ذي فئات. بناءً على ما ذكر نلاحظ ضرورة تقديم بعض المفاهيم التي لا بدّ منها لشرح الجداول التكرارية ذوات الفئات، وسنبداها بالمفهوم الآتي

(١,٤,١) تعريف (الفئة Class)

الفئة هي فترة يُصطلح عليها بحيث يكون لها طول موجب تماماً.

لقد ورد في المراجع تسميات عديدة للفئة منها: Interval أو Category أو Group أو Class. علماً أن الحد الأدنى للفئة هي القيمة التي تمثل الطرف الأيسر للفئة، وأما الطرف الأيمن للفئة فإنه القيمة التي تمثل الحد الأعلى للفئة.

(١,٤,٢) تعريف (سعة الفئة Length of Class)

سعة الفئة هو ذلك العدد الدال على **طول الفترة** التي تشغلها الفئة وتساوي الفرق بين الحد الأعلى والأدنى للفئة.

سنرمز لسعة الفئة ذات الرقم i بالرمز C_i ، وفي حال تساوي السعة لجميع الفئات سنستخدم الرمز C (بدون دليل للرمز) للدلالة على سعة الفئات.

(١,٤,٢,١) ملاحظات

١- إن سعة الفئات تختار بحسب طبيعة المسألة التي هي قيد الدرس، وهنا يجب الانتباه إلى أنه من الممكن حصولنا على فئات خالية من البيانات، وهذا النوع من الفئات غير مرغوب فيه، ولذلك عند ظهور مثل هذه الحالة علينا زيادة أو إنقاص سعة الفئة، أو أن نقوم بدمجها مع فئة سابقة لها أو لاحقة بها بحيث نحصل على فئات غير خالية من البيانات. من جهة أخرى (وكما ذكرنا آنفاً) ليس بالضرورة أن تكون سعة جميع الفئات متساوية، ولكن في حال عدم تساوي سعة الفئات تصبح الدراسة أكثر صعوبة وتعقيداً، ولهذا السبب فإننا في دراستنا المقبلة لن نتعامل إلا مع فئات متساوية السعة فقط، بمعنى أن كل الجداول التكرارية التي سنأتي على ذكرها ستكون ذات فئات متساوية السعة ما لم ننوّه بخلاف ذلك.

٢- يمكن التعديل على قيمة السعة للفئة (ولكنه ليس ملزماً) بحيث نحصل على قيمة تجعل عملية تفرغ البيانات أكثر سهولة وكذلك العمليات الحسابية المتعلقة بسعة الفئة أكثر يسراً، فعلى سبيل المثال لو كان لدينا $C = 2.37$ ، فعندئذ يمكننا أخذ القيمة $C = 2.4$ ، $C = 2.3$ ، $C = 2.5$ أو أية قيمة أخرى قريبة منها عوضاً عن تلك القيمة (ويفضل التقريب بالزيادة وليس بالنقصان) وذلك حسب طبيعة الفارق بين الفئات ورأي الباحث في هذه القيم.

(١,٤,٣) تعريف (تكرار الفئة Frequency of Class)

إن تكرار الفئة ذات الرقم i هو عدد سنرمز له بـ f_i يدل على عدد العناصر الموجودة في هذه الفئة (أو التي تنتمي إلى هذه الفئة).

الآن، ومن أجل بناء هذه الجداول يتم حساب أو اختيار قيم لسعات الفئات (سنأتي على كيفية تعيينها لاحقاً في هذا الفصل)، ومن ثمّ يعين في هذا الجدول عدة أعمدة لكل منها مهمة محدّدة، فمنها خاص بالفئات التي شكّلت، وآخر خاص بتعداد الفئات التي لدينا،

وثالثٌ يُسجَّل فيه عدد البيانات التي تنتمي لتلك الفئات المقابلة (التكرار)، وآخر لمهمةٍ أخرى وهكذا.... إنَّ هذا النوع من الجداول يستخدم (وكما ذكرنا قبل قليل) من أجل صبِّ (أو تجميع) البيانات الخام الكميَّة عندما يكون حجم البيانات كبيراً، وعند بناء هذا النوع من الجداول لابدَّ من القيام بمجموعة إجراءات هي:

- ١- التحقق من أنَّ جميع البيانات من النوع الكمي.
 - ٢- التحقق من عدم وجود بيانات مفقودة.
 - ٣- معرفة عدد الفئات المطلوبة أو ساعاتها.
- وهناك إجراءات أخرى سنأتي على ذكرها لاحقاً. لكن في الواقع يُميِّز بين نوعين من الجداول التكرارية ذوات الفئات وهما:

(١, ٤, ٤) الجداول التكرارية ذوات الفئات المنفصلة

تكون الفئات في هذا النوع من الجداول منفصلة بعضها عن البعض الآخر بمقدار وحدة قياس أو جزء من وحدة قياس، وذلك حسب طبيعة البيانات والدقة المستخدمة في أجهزة القياس التي أنتجت لنا البيانات، والعروض الجدولية الافتراضية الآتية توضح لنا ذلك. لنفترض أننا نقوم بوزن أشياء باستخدام ميزان دقته 1 كغ، فعندئذ يمكننا تقديم البيانات الناتجة في جدول منفصل الفئات على النحو الآتي (قيم التكرارات في هذه الجداول هي قيم افتراضية):

الجدول (١, ٧) أ.

رقم الفئة	الحدود للفئة	تكرار الفئة
1	3 — 7	2
2	8 — 12	5
3	13 — 17	7
4	18 — 22	4
5	23 — 27	5
Total	-----	23

فلاحظ هنا أنَّ الفاصل بين كل فئتين متتاليتين يساوي وحدة قياس كاملة. أما إذا كنا نقوم بوزن هذه الأشياء باستخدام ميزان دقته 0.1 كغ، فعندئذ يمكننا أن نقدِّم البيانات الناتجة في جدول منفصل الفئات على النحو الآتي:

الجدول (١, ٧) ب.

رقم الفئة	حدود الفئة	تكرار الفئة
1	3 — 7	2
2	7.1 — 11.1	4
3	11.2 — 15.2	8
4	15.3 — 19.3	6
5	19.4 — 23.4	3
Total	-----	23

حيثُ يلاحظ هنا أنَّ الفاصل بين كل فئتين متتاليتين يساوي جزءاً عشرياً واحداً من وحدة القياس.

وبالمثل لو كنا نقوم بوزن هذه الأشياء باستخدام ميزان دقته 0.01 كغ، فعندئذ يمكننا أن نقدم البيانات الناتجة في جدول منفصل الفئات على النحو الآتي:

الجدول (٧، ١ ج)

رقم الفئة	حدود الفئة	تكرار الفئة
1	3 — 7	2
2	7.01 — 11.01	4
3	11.02 — 15.02	9
4	15.03 — 19.03	6
5	19.04 — 23.04	2
Total	-----	23

وفي هذا الجدول يلاحظ أن الفاصل بين كل فئتين متتاليتين يساوي جزءاً مئوياً واحداً من وحدة القياس.

(١، ٤، ٤، ١) ملاحظات:

١- يمكن جعل الفارق بين فئتين متتاليتين يساوي وحدة قياس إذا ما ضربت قيم حدود الفئات بمضاعف مناسب للعشرة، ومن ثم يمكننا النظر إلى الجداول ذوات الفئات المفصلة على أنها من الشكل المقدم في الجدول الآتي (٨، ١)، حيث يشير التكرار f_1 ، f_2 ، f_3 و... في هذا النوع من الجداول إلى عدد القيم التي تنتمي إلى الفترة المغلقة $[a, b]$ ، $[b + 1, c]$ ، $[c + 1, d]$ و... على الترتيب.

الجدول (٨، ١)

رقم الفئة	حدود الفئة	تكرار الفئة
1	$a — b$	f_1
2	$b+1 — c$	f_2
3	$c+1 — d$	f_3
4	$d+1 — e$	f_4
5	$e+1 — f$	f_5
Total	-----	$\sum f_i$

٢- نشير هنا إلى أن القيم التي تُصَبّ في هذه الفئات هي تلك القيم التي نحصل عليها من قياس المشاهدات مباشرةً، ولذلك فهذه القيم ليست القيم الحقيقية للبيانات لأنها مجردة من قيمة الخطأ المرتكب من أجهزة القياس. لذلك تدعى هذه الفئات بـ **الفئات العملية (أو التجريبية)**، وحدودها يُطلق عليها اسم **الحدود العملية للفئات** Class Limits.

(١، ٤، ٥) الجداول التكرارية ذوات الفئات المتصلة

تكون الفئات في هذا النوع من الجداول متصلة بعضها مع البعض الآخر بحيث تكون نهاية كل فئة هي بداية الفئة التالية، ومن ثم يكون لهذا النوع من الجداول العرض الآتي:

جدول (٩، ١)

رقم الفئة	حدود الفئة	تكرار الفئة
1	$a \rightarrow b$	f_1
2	$b \rightarrow c$	f_2
3	$c \rightarrow d$	f_3
4	$d \rightarrow e$	f_4
5	$e \rightarrow f$	f_5
Total	-----	$\sum f_i$

وهنا نلاحظ أنَّ التكرار f_1 يكون دالاً على عدد القيم التي تنتمي للفترة نصف المغلقة $[a, b)$ ، والتكرار f_2 دالاً على عدد القيم التي تنتمي للفترة نصف المغلقة $[b, c)$ ، وهكذا دواليك...، ولذلك استخدمنا سهماً بدلاً من الشحطة للتأكيد على أنَّه لدى صبِّ البيانات الخام في هذا النوع من الجداول، فإنَّه إذا وافقت إحدى قيم البيانات للحد الأعلى للفئة فإنَّها تُصبَّ (أو تُفرَّغ) في الفئة التالية.

(١، ٤، ٥، ١) ملاحظات

١- يلجأ عادة إلى هذا النوع من الجداول إذا كانت دقة أجهزة القياس المستخدمة في توليد البيانات عالية جداً لدرجة يمكن معها إهمال الخطأ المرتكب من هذه الأجهزة، أو أن نكون غير مهتمين بقيمة الخطأ المرتكب لدى توليد البيانات حيث ينظر إلى القيم التي تم الحصول عليها من قياس المشاهدات على أنَّها القيم الحقيقية للبيانات، ولذلك تُدعى هذه الفئات بـ **الفئات الفعلية (أو الحقيقية)**، وحدود هذه الفئات تُدعى **الحدود الفعلية للفئات** Class Boundaries.

٢- نشير إلى أنَّه إذا وجدت قيم تساوي قيمة الحد الأعلى للفئة الأخيرة في الجدول التكراري فإنَّنا نقوم بضمِّها للفئة الأخيرة، وأما إذا وجدت قيم تساوي الحد الأعلى للفئة الأخيرة وأخرى أكبر من الحد الأعلى للفئة الأخيرة فإنَّنا نقوم بإضافة فئة جديدة تلي آخر فئة لتشتمل على ما تبقى من بيانات بها فيها القيم المساوية للحد الأعلى للفئة الأخيرة.

٣- إذا ظهرت لدينا فئات خالية من البيانات فإنَّنا نجري تعديلاً على عدد الفئات (ومن ثمَّ على سعة الفئات) بحيث ننفي وجود أي فئة خالية من البيانات في جدول التوزيع التكراري.

(١، ٤، ٦) حساب سعات الفئات وعددها من أجل جدول تكراري ذو فئات

بفرض أنَّه لدينا مجموعة بيانات خام x_1, x_2, \dots, x_n ، فعندئذ لحساب عدد الفئات اللازمة لبناء جدول تكراري ذي فئات خاص بهذه البيانات نتبع الخطوات الآتية:

١- حساب المدى Range لهذه البيانات، وسنرمز له بـ R ، ويُعرَّف بالعلاقة الآتية:

$$R = x_{\ell} - x_s \quad [1,3]$$

علماً أنَّ x_{ℓ} و x_s ترمزان لأكبر وأصغر قيمة في البيانات على الترتيب.

٢- إذا فُرض علينا عدد مُعيَّن من الفئات وليكن k مثلاً، فعندئذ نحسب **السعة C** لكل فئة من الجدول بوساطة العلاقة الآتية:

$$C = \frac{R}{k} \quad [1,4]$$

٣- إذا قُدِّمت لنا السعة C الواجب استخدامها لكل فئة في الجدول، فعندئذ يُحسب عدد الفئات k اللازمة لبناء هذا الجدول بوساطة العلاقة الآتية:

$$k = \left\lceil \frac{R}{C} \right\rceil \quad [1,5]$$

علماً أنَّ $\lceil x \rceil$ هو أصغر عدد صحيح أكبر من أو يساوي x .

٤- إذا لم نُعط سعة الفئات، ولم يُفرض علينا عدد معين من الفئات، فعندئذ تُستخدم العلاقة الآتية لتحديد عدد الفئات:

$$k = \lfloor 3.322 \log n \rfloor \quad [1,6]$$

وسوف ندعوه **العدد الافتراضي** Default Number للفئات، علماً أنَّ n هو عدد البيانات الخام التي ينبغي صبّها في الجدول و $\lfloor x \rfloor$ هو أكبر عدد صحيح أصغر من أو يساوي x . بعد ذلك تُحسب سعة الفئة من خلال العلاقة [1,4] مع أخذ $k = \lfloor 3.322 \log n \rfloor$ ، حيث سندعوه هذه السعة بـ **السعة الافتراضية** Default Class width.

نُشير هنا إلى أنَّ العلاقة [1,6] تُستخدم في بعض البرامج الإحصائية لتحديد العدد الافتراضي للفئات ومنها برنامج Easy Fit، حيث يلاحظ هنا التناسب الطردي لعدد الفئات مع عدد البيانات n (أو مجموع التكرارات).

(١, ٤, ٦, ١) أمثلة

١- لنقم بصبّ مجموعة البيانات (٣, ١, ١) في جدول تكراري.

من أجل ذلك يجب علينا حساب المدى R لتلك البيانات، فنجد أنَّ $R = 19 - 2 = 17$ ، وبما أنَّه لم يُقدّم لنا عدد الفئات المطلوب استخدامها فإننا سنستخدم العدد الافتراضي للفئات فنجدّه يساوي:

$$k = \lfloor 3.322 \log n \rfloor = \lfloor 3.322 \log 64 \rfloor = \lfloor 6.00 \rfloor = 6$$

ومن ثم تكون السعة الافتراضية للفئات التي سنستخدمها هي:

$$C = \frac{R}{k} = \frac{17}{6} = 2.83$$

وعلى سبيل التبسيط سنأخذ $C = 2.9$ (كان من الممكن أن نأخذ $C = 3$ أيضاً)، والفاصل بين كل فئتين منفصلتين متتاليتين يساوي 0.1 (أي افترضنا أنَّ دقّة القياس 0.1). بالطبع يجب الانتباه هنا إلى القيمة التي سنأخذها كفاصل بين كل فئتين متتاليتين، فلو أخذنا (على سبيل المثال) هذه القيمة مساويةً لوحدة قياس صحيحة (أي بمقدار 1) فإنَّ الفئة السادسة ستصبح خارج نطاق البيانات (أي ستصبح فئة خالية).

الآن بصبّ بيانات المجموعة (٣, ١, ١) في جدول تكراري وفقاً لما شرحناه آنفاً سنحصل على الجدول التكراري (١٠, ١) في حال استخدامنا فئات منفصلة، وأما في حال استخدامنا فئات متصلة فإنّه سيكون للبيانات (٣, ١) الجدول التكراري (١٠, ١ ب).

الجدول (١٠, ١ أ)

رقم الفئة	حدود الفئة	تكرار الفئة
1	2 — 4.9	3
2	5 — 7.9	12
3	8 — 10.9	7
4	11 — 13.9	31
5	14 — 16.9	7
6	17 — 19.9	4
Total	-----	64

الجدول (١٠, ١.ب)

رقم الفئة	حدود الفئة	تكرار الفئة
1	2 → 4.9	3
2	4.9 → 7.8	12
3	7.8 → 10.7	7
4	10.7 → 13.6	31
5	13.6 → 16.5	7
6	16.5 → 19.4	4
Total	-----	64

فلاحظ هنا أنه من أجل هذا المثال لم تتغير قيم التكرارات في كلا الحالتين، ولكن هذا ليس قاعدة عامة، فمن الممكن أن تتغير قيم التكرارات في حال الانتقال من جدول تكراري منفصل الفئات إلى جدول تكراري متصل الفئات والمثال الآتي يوضح لنا ذلك.

٢- لنأخذ البيانات الخام الآتية:

9 2 11 11 2 9 9 2 9 6 5 5 5 11 15 17 15 13
6 9 5 7 7 4 4 4 5 5 7 4 13 4 13 19 13 19

ولنقم بصب هذه البيانات في جدول تكراري بفئات منفصلة ذات سعة تساوي 3 فإنه سيكون للبيانات المعطاة الجدول التكراري (١١, ١.أ)، وأما إذا صُبت البيانات في جدول تكراري بفئات متصلة ذات سعة تساوي 3 فإننا سنحصل على الجدول التكراري (١١, ١.ب) للبيانات المعطاة.

الجدول (١١, ١.أ)

رقم الفئة	حدود الفئة	تكرار الفئة
1	2 — 5	14
2	6 — 9	10
3	10 — 13	7
4	14 — 17	3
5	18 — 21	2
Total	-----	36

الجدول (١١, ١.ب)

رقم الفئة	حدود الفئة	تكرار الفئة
1	2 → 5	8
2	5 → 8	11
3	8 → 11	5
4	11 → 14	7
5	14 → 17	2
6	17 → 20	3
Total	-----	36

حيث يتضح لنا تغير قيم التكرارات وعدد الفئات أيضاً.

(١, ٤, ٧) جداول التوزيع التكرارية Frequency Distribution Tables:

في الواقع يمكن تمديد الجداول التكرارية ذوات الفئات بحيث تصبح أكثر فاعلية في تنفيذ بعض العمليات الحسابية الخاصة بالبيانات وكذلك توضيح شكل التوزيع للبيانات، ومن ثم إضفاء صفة العمومية على هذه الجداول. لذلك فإن كل ما تم شرحه سابقاً بشأن الجداول التكرارية يبقى ساري المفعول من أجل هذه الجداول باستثناء ما يشار إليه في الدراسة التالية. إن هذه الجداول تُعرف باسم **جداول التوزيع التكرارية** ولها نماذج مختلفة ولكن معظم هذه الجداول تحتوي على أعمدة من أجل:

١- الرقم المتسلسل للفئات Number of Classes:

في هذا العمود يدون فيه أرقام متسلسلة دالة على رقم الفئات في الجدول (كما سبق واستخدم في الجداول التكرارية)، وينتهي الترقيم مع القيمة التي تُحدد عدد الفئات حيث كنا قد ذكرنا سابقاً كيفية تعيين عدد الفئات لجدول توزيع تكراري، ولكن من أجل هذا النوع من الجداول التكرارية يُراعى عند اختيار عدد الفئات ما يلي:

أ- يجب ألا يقل عدد الفئات عن خمس، وهذا يوافق الحالة التي يكون فيها عدد البيانات المراد صيها لا يقل عن 32 قيمة وفقاً للعدد الافتراضي للفئات $k = \lfloor 3.322 \log n \rfloor$ حيث لدينا $n = 10^{\frac{5}{3.322}} \approx 32$ ، وهذا يتضح لنا من خلال العلاقتين الآتيتين أيضاً:

$$k = \lfloor 3.322 \log 31 \rfloor = \lfloor 4.954304 \rfloor = 4$$

$$k = \lfloor 3.322 \log 32 \rfloor = \lfloor 5.000108 \rfloor = 5$$

ولذلك سنقول عن بيانات معطاة إنها قليلة العدد (أو عينة صغيرة الحجم) إذا كان $n > 32$ ، وخلاف ذلك نعدّها كثيرة العدد أو عينة كبيرة الحجم.

ب- يجب ألا يزيد عدد الفئات عن العشرين، وهذا يوافق الحالة التي يكون فيها عدد البيانات الخام المراد صيها لا يزيد عن 10^6 وفقاً للعدد الافتراضي للفئات حيث لدينا $n = 10^{\frac{20}{3.322}} \approx 10^6$ ، وسبب ضرورة تحقق البندين السابقين هو أنه في الحالة الأولى يصبح الجدول غير عملي في الدراسة الإحصائية للظاهرة التي هي قيد البحث وخاصة إذا كان حجم العينة كبيراً بما فيه الكفاية، وفي الحالة الثانية يصبح الجدول مجهداً في دراسته، ولكنه لبعض الضرورات يمكن تجاهل البندين السابقين مثل الحالات التي يكون فيها حجم البيانات التي نود صيها كبير جداً (كالتعداد السكاني الشامل)، أو إذا كنا بحاجة لصب مجموعة بيانات بحجم 30 أو 31 في جدول توزيع تكراري بخمس من الفئات فقط.

٢- الحدود العملية (أو التجريبية) للفئات Class Limits:

يدون في هذا العمود الفئات المتتالية بشكلها المنفصل (فئات منفصلة) على النحو الذي تم شرحه سابقاً في فقرة الجداول التكرارية ذوات الفئات المنفصلة، وموضحاً فيها قيم حدي كل فئة، وتؤخذ عادة أصغر قيمة للبيانات الخام كحد أدنى للفئة الأولى.

٣- الحدود الفعلية (أو الحقيقية) للفئات Class Boundaries:

يدون في هذا العمود فئات تكون فيها قيم حدّها الأدنى أقل بمقدار نصف وحدة عن حد الفئة العملية (حسب الوحدة المستخدمة في دقة القياس كفاصل بين كل فئتين، حيث قمنا بتوضيح ذلك سابقاً)، وأما حدّها الأعلى فإنه يزيد بمقدار نصف وحدة عن حد الفئة العملية، وعلى ألا تأخذ قيمة الحد الأعلى للفئة كجزء من الفئة الفعلية، أي إن الفئات الناتجة عن هذه العملية ستكون على شكل فترات نصف مفتوحة من الشكل $[a, b)$. لذلك تصبح الفئات المتتالية في هذا العمود متصلة بعضها مع البعض الآخر. إن السبب في أخذ هذا النوع من الفئات هو أنه لدى عملية تحصيل البيانات سيكون لدينا خطأ مركب من وسائل القياس المعتمدة (مهما بلغت من

دقة)، ولذلك اصطلاح على أن نصف وحدة قياس ستغطي الخطأ المرتكب زيادة أو نقصاناً، ولذلك ستحتوي هذه الفئات على القيم الحقيقية (أو الفعلية) للبيانات، ولهذا السبب دُعيت هذه الفئات بـ **الفئات الفعلية**. هنا نشير إلى أن سعة الفئة الفعلية C تحسب من أجل هذا النوع من الجداول باستخدام العلاقة الآتية عندما يكون عدد الفئات المعطاة يساوي k :

$$C = \frac{R + \text{one measuring unit}}{k}$$

و أما في حال كان عدد الفئات غير معطى فإننا نستخدم العلاقة الآتية لحساب السعة:

$$C = \frac{R + \text{one measuring unit}}{\lfloor 3.322 \log n \rfloor}$$

إن إضافة وحدة القياس إلى قيمة المدى لأجل تغطية الخطأ الأعظمي المرافق لقياس أكبر وأصغر قيمة في البيانات.

بعد ذلك نقوم بتعيين حدود الفئات الفعلية كما يلي:

أ- نجعل الحد الأدنى لأول فئة فعلية مساوياً للقيمة الناتجة عن طرح نصف وحدة (حسب الوحدة المستخدمة في دقة القياس) من أصغر قيمة في البيانات.

ب- نضيف قيمة C إلى الحد الأدنى للفئة الأولى فنحصل على الحد الأعلى للفئة الفعلية الأولى.

ج- نجعل الحد الأدنى للفئة الفعلية التالية (الثانية) مساوياً للحد الأعلى للفئة الفعلية السابقة (الأولى)، ومن ثم نضيف قيمة C إلى الحد الأدنى لهذه الفئة فنحصل على الحد الأعلى للفئة الفعلية الثانية.

د- نقوم بتطبيق الفقرة السابقة (ج) من أجل جميع الفئات المتبقية فنحصل على الحدود الدنيا والعليا للفئات الفعلية لجداول التوزيع التكراري.

نشير هنا إلى أنه في كثير من الحالات يُستغنى عن عرض عمود حدود الفئات العملية Class Limit لأنَّ صَبَّ (أو تفرغ) البيانات الخام في هذا النوع من الجداول يتم في الفئات الفعلية حصراً، وكذلك الدراسات اللاحقة لسلوك بيانات جداول التوزيع التكرارية من عروض بيانية ومقاييس عددية تعتمد جميعها على عمود الفئات الفعلية فقط.

٤ - مراكز الفئات Midpoints:

يُدَوَّن في هذا العمود، ومقابل الفئة التي هي قيد المسح، قيمة تدلُّ على مركز هذه الفئة، وقيمه تساوي نصف مجموع حدِّها الأعلى والأدنى، علماً أنَّه يُنظر إلى قيمة مركز الفئة على أنَّه القيمة الممثلة للفئة، وسنرمز بـ x_i لقيمة مركز الفئة ذات الرقم i .

٥ - تعداد عناصر الفئات Tally:

يرسم في هذا العمود، ومقابل الفئة التي هي قيد المسح، خطاً من الشكل | عن كل بيان ينتمي لهذه الفئة التي هي قيد المسح، وبحيث تُجمَع كل خمسة خطوط على شكل حزمة ||||، وغالباً ما يُحذف هذا العمود لأنَّ عمود تكرار الفئات (الذي سيقدِّم في الفقرة التالية) يُغني عن هذا العمود.

٦ - تكرار الفئات Frequency:

في هذا العمود يُدَوَّن التكرار للفئة التي هي قيد المسح على النحو الذي ذكرناه سابقاً، وسنرمز بـ f_i لقيمة تكرار الفئة ذات الرقم i .

٧ - التكرار النسبي للفئات Relative Frequency:

في هذا العمود يُدَوَّن التكرار النسبي للفئة التي قيد المسح، وقيمه هي حاصل قسمة تكرار الفئة المعنية على المجموع الكلي للتكرارات، وغالباً يُحذف هذا العمود من جدول التوزيع التكراري لأنَّ قيمه تُستنتج من القيم الموجودة في عمود تكرار الفئات.

٨- التكرار المئوي (تكرار النسبة المئوية) للفئات Percentage Frequency:

في هذا العمود يدون التكرار المئوي (أو تكرار النسبة المئوية) للفئة التي هي قيد المسح، وقيمة هذا التكرار ينتج من خلال ضرب التكرار النسبي للفئة بالعدد 100 ويقرأ كنسبة مئوية، وغالباً يُحذف هذا العمود؛ لأنه يستنتج من القيم الموجودة في عمود تكرار الفئات أيضاً.

٩- التكرار المتجمع الصاعد للفئات Ascending Cumulative Frequency:

في هذا العمود، ومقابل الفئة التي هي قيد المسح، يدون عدد البيانات التي قيمها أقل من قيمة الحد الأعلى لهذه الفئة، ومن ثم يكون التكرار المتجمع الصاعد لفئة يساوي مجموع تكرار الفئة مع جميع التكرارات للفئات السابقة لها، وسنرمز بـ F_i لقيمة التكرار المتجمع الصاعد للفئة ذات الرقم i .

١٠- التكرار المتجمع الهابط للفئات Descending Cumulative Frequency:

في هذا العمود، ومقابل الفئة التي هي قيد المسح، يدون عدد البيانات التي قيمها أكبر من قيمة الحد الأدنى لهذه الفئة، وهو نادر الاستخدام، ولذلك لا يدرج في جدول التوزيع التكراري إلا عند الحاجة له. بهذا يكون لجدول التوزيع التكراري العرض الآتي:

الجدول (١٢، ١)

التكرار المتجمع الهابط للفئة	التكرار المتجمع الصاعد للفئة	التكرار المئوي	التكرار النسبي للفئة	تكرار الفئة	تعداد الفئة	مركز الفئة	الحدود الفعلية للفئة	الحدود العملية للفئة	رقم الفئة
	F_i			f_i		x_i			i
...	1
...	2
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
المجموع	-----				-----	-----	-----	-----	Total

١, ٤, ٧, ١٠ ملاحظات

١- نوكد هنا أنه عند صبّ (أو تفرغ) البيانات الخام في جدول توزيع تكراري فإنه يتم بناءً على قيم الحدود الفعلية للفئات، بمعنى أن التفرغ يتم في الفئات الفعلية وليس في الفئات العملية، وتُحسب سعة الفئة الفعلية C باستخدام العلاقة [1,4] مع أخذ قيمة عدد الفئات $k = \lfloor 3.322 \log n \rfloor$.

٢- إذا طُلب منا صبّ البيانات الخام في جدول توزيع تكراري بفئات عملية ذات سعة محدّدة فإننا نقوم بتعيين الفئات العملية في الجدول، ومن ثم نستنتج منها الفئات الفعلية التي ستصبّ فيها البيانات.

٣- عندما تكون أصغر الفروق بين البيانات أعداداً صحيحة فإنه يمكن أخذ قيمة الفاصل بين الفئة العملية والفئة التالية لها من الشكل 10^k مع $k=0,1,2,...,n$ و n عدد صحيح غير سالب، فعلى سبيل المثال إذا كانت أصغر الفروق بين البيانات من مرتبة الآحاد فإننا نستخدم الفاصل بين الفئة العملية والفئة التالية لها بمقدار يساوي الواحد (أي 10^0) وتكون الدقة المعتمدة في هذه الحالة تساوي ± 0.5 ، وأما إذا كانت أصغر الفروق بين البيانات من مرتبة العشرات فإننا نستخدم الفاصل بين الفئة العملية والفئة التالية لها بمقدار يساوي عشرة (أي 10^1) وتكون الدقة المعتمدة في هذه الحالة تساوي ± 5 ، وهكذا دواليك.... أما إذا كانت هناك بعض القيم غير الصحيحة فعندئذ يجب النظر في القيمة التي ستستخدم كفاصل بين الفئات وفقاً لما تسمح به المسألة المدروسة.

٥- إضافة لما سبق فإنه من الممكن أن يتضمن جدول التوزيع التكراري السابق بعض الأعمدة الأخرى مثل التكرار المتجمع الصاعد النسبي والتكرار المتجمع الهابط النسبي، ولكن هذه الأعمدة تُضاف إلى جدول التوزيع التكراري عند الحاجة لها فقط.

(٢, ٧, ٤, ١) أمثلة

١- لتكن لدينا مجموعة البيانات الخام الآتية:

3	4	7	11	7	9	2	5	7	2
8	4	8	6	4	10	5	3	10	3
9	5	6	5	8	6	5	6	9	6
10	9	7	11	7	7	9	7	9	7

ولنقم بصب هذه البيانات في جدول توزيع تكراري.

التنفيذ: من أجل ذلك لنقم أولاً بحساب المدى لهذه البيانات، حيث لدينا من العلاقة [1,3] ما يلي:

$$R = x_{\ell} - x_s = 11 - 2 = 9$$

وبما أنه لم نُعطِ سعة الفئات، ولم يُفرض علينا عدد معين من الفئات، فعندئذُ نستخدم العلاقة [1,6] لحساب العدد الافتراضي للفئات، فيكون لدينا:

$$k = \lfloor 3.322 \log 40 \rfloor = \lfloor 5.22 \rfloor = 5$$

ومن ثمَّ نحسب السعة الافتراضية C لكل فئة فعلية من الجدول بوساطة العلاقة [1,4] حيث لدينا:

$$C = \frac{R + one\ measuring\ unit}{k} = \frac{9 + 1}{5} = 2$$

وهكذا يكون الحد الأدنى لأول فئة فعلية يساوي $1.5 = 0.5 - 2$ ، ولكن وفقاً لهذه السعة من الممكن أن تبقى لدينا قيم خارج نطاق الفئة الفعلية الأخيرة، ولذلك إما أن نزيد من سعة الفئة قليلاً أو نضطر إلى إضافة فئة سادسة، وهذا يوضحه لنا الجدول الآتي:

الجدول (١٣, ١.١)

من أجل C = 1.8		من أجل C = 2	
الحد الأدنى للفئة	الحد الأعلى للفئة	الحد الأدنى للفئة	الحد الأعلى للفئة
1.5	3.3	1.5	3.5
3.3	5.1	3.5	5.5
5.1	6.9	5.5	7.5
6.9	8.7	7.5	9.5
8.7	10.5	9.5	11.5

وباتباع الخطوات التي قمنا بشرحها سابقاً فإننا سنميز التفريغ للبيانات باستخدام لون خاص لكل فئة (وذلك على سبيل التوضيح فقط) فيكون لدينا العرض الآتي للبيانات المعدّة للتفريغ:

3	4	7	11	7	9	2	5	7	2
8	4	8	6	4	10	5	3	10	3
9	5	6	5	8	6	5	6	9	6
10	9	7	11	7	7	9	7	9	7

وبتفريغ هذه البيانات سنحصل على جدول التوزيع التكراري الآتي (١٣, ١.ب) الذي يحتوي على الفئات الفعلية، والفئات العملية، ومراكز الفئات، والتعدادات، والتكرارات بأنواعها المشروحة سابقاً (لقد تم تجزئة الجدول إلى جدولين بسبب كبر حجم الجدول وضيق الحيز المتاح له).

الجدول (١٣, ١.ب)

رقم الفئة	لحدود العملية للفئة	لحدود الفعلية للفئة	مركز الفئة	تعداد الفئة	تكرار الفئة	التكرار النسبي للفئة
1	2 – 3	1.5 → 3.5	2.5		5	5/40 = 0.125
2	4 – 5	3.5 → 5.5	4.5		8	8/40 = 0.200
3	6 – 7	5.5 → 7.5	6.5		13	13/40 = 0.325
4	8 – 9	7.5 → 9.5	8.5		9	9/40 = 0.225
5	10 – 11	9.5 → 11.5	10.5		5	5/40 = 0.125
Total	-----	-----	-----	-----	40	1

الجدول (١٣, ١.ب)

رقم الفئة	لحدود الفعلية للفئة	تكرار الفئة	التكرار المئوي للفئة %	التكرار المتجمع الصاعد للفئة	التكرار المتجمع الهابط للفئة
1	1.5 → 3.5	5	0.125×100	5	5+8+13+9+5=40
2	3.5 → 5.5	8	0.200×100	5+8=13	8+13+9+5=35
3	5.5 → 7.5	13	0.325×100	5+8+13=26	13+9+5=27
4	7.5 → 9.5	9	0.225×100	5+8+13+9=35	9+5=14
5	9.5 → 11.5	5	0.125×100	5+8+13+9+5=40	5
Total	-----	40	100 %	المجموع	المجموع

الجدولين السابقين هما بمثابة جدول واحد

٢- صبّ مجموعة البيانات (١٣, ١.أ) في جدول توزيع تكراري بحيث تكون سعة الفئة العملية فيه تساوي C = 2.5 ، وبحيث يكون الفاصل بين الفئات العملية يساوي الواحد تماماً.

التنفيذ: نلاحظ هنا أنه فرض علينا سعة الفئات العملية والقيمة التي تفصل بينها، ولذلك علينا أولاً أن نعين الفئات العملية ومن ثم نستنتج منها الفئات الفعلية.

من أجل ذلك سنأخذ أصغر قيمة في مجموعة البيانات (١٣, ١.أ) كحد أدنى للفئة العملية الأولى فتكون الفئة العملية الأولى ممثلة بالفترة [2 , 4.5] والثانية بالفترة [5.5 , 8] وهكذا دواليك...، وبما أن الدقة المعتمدة لدى الحصول على البيانات تساوي ±0.5، فإنه سيكون لتلك البيانات جدول التوزيع التكراري المقدم في الجدول الآتي (١٣, ١.ج) (الجدولين هما بمثابة جدول واحد، وجزئنا لضيق الحيز المخصص لعرضهما في جدول واحد).

الجدول (١٣، ١ ج)

رقم الفئة	الحدود الفعلية للفئة	الحدود العملية للفئة	مركز الفئة	تعداد الفئة	تكرار الفئة	التكرار النسبي للفئة
1	2.0 – 4.5	1.5 → 5	3.25		3	3/64 = 0.0469
2	5.5 – 8.0	5 → 8.5	6.75		12	12/64 = 0.1875
3	9.0 – 11.5	8.5 → 12	10.25		17	17/64 = 0.2656
4	12.5 – 15	12 → 15.5	13.75		28	28/64 = 0.4375
5	16 – 18.5	15.5 → 19	17.25		3	3/64 = 0.0469
6	19.5 – 22	19 → 22.5	20.75		1	1/64 = 0.0156
Total	-----	-----	-----	-----	64	1

الجدول (١٣، ١ ج).

رقم الفئة	الحدود الفعلية للفئة	تكرار الفئة	التكرار المئوي للفئة %	التكرار المتجمع الصاعد للفئة	التكرار المتجمع الهابط للفئة
1	1.5 → 5	3	0.0469×100	3	3+12+17+28+3+1=64
2	5 → 8.5	12	0.1875×100	3+12=15	12+17+28+3+1=61
3	8.5 → 12	17	0.2656×100	3+12+17=32	17+28+3+1=49
4	12 → 15.5	28	0.4375×100	3+12+17+28=60	28+3+1=32
5	15.5 → 19	3	0.0469×100	3+12+17+28+3=63	3+1=4
6	19 → 22.5	1	0.0156×100	3+12+17+28+3+1=64	1
Total	-----	64	100 %	المجموع	المجموع

الجدولين السابقين هما بمثابة جدول واحد

(١, ٤, ٧, ٣) ملاحظات:

١ - بناءً على التنويهات التي وردت سابقاً يمكن اختزال جدول التوزيع التكراري (١, ١٢) بحيث يحتوي الفئات الضرورية منها فقط، ومن ثم استخدام عدد أقل من الأعمدة (وهذا بدوره يجعل الدراسة أكثر سراً وبساطة)، حيث يصبح لدينا جدول توزيع تكراري مختزل له العرض الآتي:

الجدول (١٤، ١)

رقم الفئة	الحدود الفعلية للفئة	مركز الفئة	تكرار الفئة	التكرار المتجمع الصاعد للفئة
Number of Classes	Class Boundaries	Midpoints	Frequency	Ascending Cumulative Frequency
1
2
⋮	⋮	⋮	⋮	⋮
Total	-----	-----		-----

علماً أن جدول التوزيع التكراري (١, ١٢) المقدم سابقاً ينظر إليه كجدول نموذجي لعرض البيانات، وقد تم حذف أعمدة الحدود العملية للفئات، والتعداد، والتكرار النسبي، والتكرار المئوي، والتكرار المتجمع الهابط للأسباب التي ذكرتها سابقاً. أي إننا سنتعامل في دراستنا المقبلة مع الحدود الفعلية للفئات فقط.

٢- لقد لاحظنا أنه يمكننا حساب المدى لبيانات خام بوساطة العلاقة [1,3] ، وأما إذا كانت البيانات مجمعة في جدول توزيع تكراري بـ k فئة مع x_1 مركز الفئة الأولى، x_2 مركز الفئة الثانية، ... و x_k مركز الفئة الأخيرة k ، فإن المدى R لبيانات هذا الجدول يُحسب بوساطة العلاقة الآتية:

$$R = x_k - x_1 \quad [1,7]$$

(١,٥) العروض البيانية لبيانات جداول التوزيع التكرارية

Graphic representations of Frequency distribution tables

في كثير من الحالات يكون التعامل مع جداول التوزيع التكرارية أمراً شاقاً، وخاصة إذا كان عدد الفئات كبيراً، ولذلك يلجأ إلى عرض النتائج من خلال أشكال بيانية مناسبة يسهل معها فهم طبيعة وسلوك البيانات، ومن هذه الأشكال البيانية ما يلي:

(١,٥,١) المدرجات التكرارية Frequency Histograms

إن المدرج التكراري هو تمثيل بياني لبيانات مجمعة في فترات، ويتكون هذا المدرج من أعمدة مستطيلة متلاصقة تُرسم فوق الفترات، وبحيث تكون مساحة كل مستطيل متناسبة مع التكرار وطول الفترة التي رُسم عليها.

(١,٥,١,١) ملاحظة


١- بما أننا نتعامل مع فئات فعلية متساوية السعة فإن ارتفاع الأعمدة المستطيلة التي تُرسم فوق الفئات الفعلية ستكون متناسبة مع تكرار القيم الواقعة في الفئة الفعلية التي رُسم عليها فقط.

٢- من أجل بيانات مجمعة في جدول توزيع تكراري مُعطى يتم عرض المدرج التكراري الموافق لذلك الجدول من خلال رسم أعمدة مستطيلة فوق الفئات الفعلية (الفئات الفعلية في جداول التوزيع التكرارية توافق الفترات المذكورة آنفاً) بحيث يكون ارتفاع كل مستطيل متناسباً مع تكرار الفئة التي رُسم عليها.

٣- نشير هنا إلى أنه إذا كانت البيانات مقدمة من خلال جدول توزيع تكراري بفئات منفصلة ولم يذكر فيه الحدود الفعلية للفئات فعندئذ يجب تعيين الفئات الفعلية أولاً ومن ثم رسم الأعمدة عليها.


(١,٥,١,٢) أمثلة

١- يعرض الشكل الآتي مدرجاً تكرارياً لـ 80 قيمة (بيانات) مجمعة في سبع فئات حيث يلاحظ أن الفئة الأولى (45 , 50) تحتوي على 5 قيم، في حين تحتوي الفئة التالية (50 , 55) على 10 قيم، وهكذا على هذا النحو تستنتج بقية التكرارات للفئات المتبقية.




الشكل (١,١٧)

٢- بالرجوع إلى المثال / ١ / من (٢, ٧, ٤, ١) نجد أن المدرج التكراري لبيانات جدول التوزيع التكراري (١٣, ١.ب) له الشكل (١٨, ١) الآتي.



الشكل (١٨, ١)

٣- بالرجوع إلى مجموعة البيانات (٣, ١.أ) نجد الشكل الآتي لمدرجها التكراري الموافق للجدول (١٣, ١.ج):



الشكل (١٩, ١)

بالإضافة لما سبق يندرج تحت مسمى مدرجات التوزيع التكرارية النماذج الآتية:


(١, ٥, ١, ٣) المدرج التكراري النسبي (أو مدرج نسبة التكرارات) Relative Frequency Histogram

إن المدرج التكراري النسبي هو تمثيل بياني آخر لبيانات مجمعة في فترات (أو فئات فعلية) متتالية ويتكون من أعمدة مستطيلة متلاصقة أيضاً، وبحيث تكون مساحة كل مستطيل متناسبة مع التكرار النسبي للقيم الواقعة في الفترة (أو الفئة الفعلية) التي رسم عليها، ومن أجل مجموعة بيانات مجمعة محددة سيكون شكل المدرج التكراري النسبي مشابهاً تماماً لشكل المدرج التكراري والاختلاف بينهما يكمن في وحدات القياس على محور التكرارات فقط. أما من أجل بيانات مجمعة في جدول توزيع تكراري معطى فيتم عرض المدرج التكراري النسبي الموافق لذلك الجدول من خلال رسم أعمدة مستطيلة فوق الفئات الفعلية بحيث يكون ارتفاع كل مستطيل متناسباً مع التكرار النسبي للفئة التي رسم عليها.

(١, ٣, ١, ٥) أمثلة

١- بالرجوع إلى بيانات المثال / ١ / من (١, ٤, ٧, ٢) نجد لمدّجها التكراري النسبي الشكل الآتي:


Relative Frequency



الشكل (١, ٢٠)

٢- بالرجوع إلى مجموعة البيانات (٣, ١, ٥) نجد الشكل الآتي لمدّجها التكراري النسبي الموافق للجدول (١٣, ١, ج):

Relative Frequency



الشكل (١, ٢١)


(١, ٤, ١, ٥) المدّج التكراري المئوي (أو مدّج تكرارات النسبة المئوية) Percentile Frequency Histogram

إنّ المدّج التكراري المئوي هو تمثيل بياني آخر لبيانات مجمعة في فئات متتالية أيضاً، ويتكوّن من أعمدة مستطيلة متلاصقة، وبحيث تكون مساحة كل مستطيل متناسبة مع التكرار المئوي للقيم الواقعة في الفئة التي رسم عليها، ولذلك من أجل مجموعة بيانات مجمعة محدّدة يكون شكل المدّج التكراري المئوي مشابهاً تماماً لشكل المدّج التكراري والنسبي، والاختلاف بينهما يكمن في وحدات القياس على محور التكرارات فقط.

(١, ٥, ١, ٥) أمثلة

١- الشكل الآتي يعرض لنا المدّج التكراري المئوي للبيانات الـ 80 الممثّلة بالمدّج التكراري المعطى بالشكل (١٥, ١)، حيث يلاحظ أنّ النسبة المئوية للبيانات في الفترة الأولى (50, 45] تساوي $100\% \times (5/80)$ في حين أنّنا نجد أنّ النسبة المئوية للبيانات في الفترة التالية (55, 50] هي $100\% \times (10/80)$ ، وعلى هذا النحو نستنتج بقية التكرارات النسبية في بقية الفترات.


Percentile Frequency %



الشكل (١, ٢٢)

٢- بالرجوع إلى بيانات المثال / ١ / من (١, ٤, ٧, ٢) نجد لمدرجها التكراري المتوي الشكل الآتي:


Percentile Frequency %



الشكل (١, ٢٣)

٣- بالرجوع إلى مجموعة البيانات (٣, ١, أ) نجد الشكل الآتي لمدرجها التكراري المتوي الموافق للجدول (١٣, ١, ج):

Percentile Frequency %



الشكل (١, ٢٤)

٤- لتكن لدينا مجموعة البيانات الآتية التي تمثل الطول لـ 58 شخصاً بالغاً مقدرةً بالسنتيمتر:

208 186 167 194 155 203 171 182 167 169 155 173 170 159 171
171 181 199 185 149 153 170 172 186 168 184 152 167 167 190
193 165 172 180 179 180 177 148 166 150 191 181 172 170 159
160 187 173 173 140 154 196 185 184 165 172 175 145

ولنقم بصب هذه البيانات في جدول توزيع تكراري بحيث تكون سعة الفئات الفعلية فيه تساوي $C = 10$ ، فنجد أن عدد الفئات المطلوبة لهذا الجدول يساوي:


$$k = \left\lceil \frac{R}{C} \right\rceil = \left\lceil \frac{(208 - 140) + 1}{10} \right\rceil = \lceil 6.9 \rceil = 7$$

ومن ثم يكون لجدول التوزيع التكراري للبيانات المعطاة العرض الآتي:

الجدول (١٥، ١)

رقم الفئة	الحدود الفعلية للفئة	تكرار الفئة	التكرار النسبي للفئة	التكرار المئوي للفئة	التكرار المتجمع الصاعد للفئة
1	140 → 150	4	0.0690	6.90 %	4
2	150 → 160	8	0.1379	13.79 %	12
3	160 → 170	10	0.1724	17.24 %	22
4	170 → 180	16	0.2759	27.59 %	38
5	180 → 190	12	0.2069	20.69 %	50
6	190 → 200	6	0.1034	10.34 %	56
7	200 → 210	2	0.0345	3.45 %	58
Total	-----	58	1	100 %	المجموع

فنجذ أن المدرج التكراري، المدرج التكرار النسبي ومدرج التكرار المئوي الموافق لبيانات هذا الجدول يعرضها لنا الشكل الآتي:



لاحظ أن الشكل البياني نفسه للمدرجات الثلاث والاختلاف في وحدات القياس على محور التكرارات فقط.


(٢, ٥, ١) المضلعات التكرارية Frequency Polygons:

يُنظر في بعض الحالات إلى أنَّ كل فئة يمكن تمثيلها بمركزها، وهذا يقودنا إلى إنشاء ما يسمَّى بـ **المضلع التكراري** (المضلع التكراري النسبي، المضلع التكراري المئوي) الذي يُشكِّل من خلال الوصل بقطع مستقيمة بين تلك النقاط التي إحداثياتها على محور الفئات هي مراكز الفئات، وأما إحداثياتها على محور التكرارات (التكرارات النسبية، التكرارات المئوية) فهي قيم التكرارات (التكرارات النسبية، التكرارات المئوية) المقابلة لتلك الفئات، وبعد ذلك إغلاق هذا المضلع إلى محور الفئات من خلال وصل بداية المضلع الناتج إلى مركز فئة وهمية سابقة لأول فئة تكرارها (تكرارها النسبي، تكرارها المئوي) معدوم، وبعد ذلك وصل نهاية المضلع الناتج إلى مركز فئة وهمية لاحقة بآخر فئة تكرارها (تكرارها النسبي، تكرارها المئوي) معدوم.

إنَّ الشكل البياني للمضلعات التكرارية الثلاث (المضلع التكراري، المضلع التكراري النسبي، المضلع التكراري المئوي) متشابهة تماماً، والاختلاف فيما بينها يكمن في وحدات القياس على محور التكرارات فقط.

(١, ٢, ٥, ١) مثال:

بالرجوع إلى بيانات جدول التوزيع التكراري (١, ١٥) السابق فإننا نجد المضلع التكراري (المضلع التكراري النسبي، المضلع التكراري المئوي) للبيانات كما في الشكل الآتي (حيث نلاحظ أنَّ الشكل البياني نفسه للمضلعات الثلاث والاختلاف في وحدات القياس على محور التكرارات فقط).



الشكل (١, ٢٦). المضلع التكراري لبيانات الجدول (١, ١٥).

(٢, ٥, ٢, ٢) ملاحظة

نشير هنا إلى أنَّ بعض المراجع تقوم بإغلاق الطرف الأيسر للمضلع إلى بداية الفئة الأولى، وإغلاق الطرف الأيمن للمضلع إلى نهاية الفئة الأخيرة، ويمكن استخدام مثل هذا الأسلوب في الإغلاق من أجل بعض الحالات الخاصة (انظر الشكل (١, ٢٦) ب).
التمرين القادم / ١ / من (١, ٥, ٥).


المضلّعات التكرارية التراكمية Cumulative Frequency Paragons (١, ٥, ٣)

من أجل هذا النوع من المضلّعات التكرارية نميّز بين نوعين من المضلّعات وهما:

Ascending Cumulative Frequency Paragon مضلع التكرار المتجمّع الصاعد (١, ٥, ٣, ١)


إنّ مضلع التكرار المتجمّع الصاعد (ويدعى أقل من القوس القوطي أيضاً **Less than Ogive**) ينشأ هذا المضلع من خلال الوصل بقطع مستقيمة بين النقاط الناشئة عن الحدود العليا للفئات الفعلية والقيم الموافقة لها من التكرار المتجمّع الصاعد، ومن ثمّ إغلاق بدايته مع بداية الفئة الأولى.

على سبيل المثال لو أخذنا بيانات جدول التوزيع التكراري (١, ١٥) السابقة لوجدنا أنّ مضلع التكرار المتجمّع الصاعد لتلك البيانات له الشكل الآتي:

**Descending Cumulative Frequency Polygon مضلع التكرار المتجمّع الهابط (١, ٥, ٣, ٢)**

إنّ مضلع التكرار المتجمّع الهابط (ويدعى أكثر من القوس القوطي أيضاً **More than Ogive**) ينشأ هذا المضلع من الوصل بقطع مستقيمة بين النقاط الناشئة عن الحدود الدنيا للفئات الفعلية والقيم الموافقة لها من التكرار المتجمّع الهابط، ومن ثمّ إغلاقه مع نهاية الفئة الأخيرة، وهذا النوع من المضلّعات قليل الاستخدام.

الشكل الآتي يعرض لنا مضلع التكرار المتجمّع الهابط لبيانات الجدول (١, ١٥).



علماً أنّ التكرار المتجمّع الهابط لبيانات الجدول (١, ١٥) موضّح في الجدول الآتي:

الجدول (١٦, ١).

رقم الفئة	الحدود الفعلية للفئة	تكرار الفئة	التكرار المتجمع الهابط للفئة
1	140 → 150	4	58
2	150 → 160	8	54
3	160 → 170	10	46
4	170 → 180	16	36
5	180 → 190	12	20
6	190 → 200	6	8
7	200 → 210	2	2
Total	-----	58	-----

إنَّ كلاً من عبارتي "أقل من القوس القوطي" و "أكثر من القوس القوطي" مرتبطة بطريقة أخذ التكرارات التراكمية عند بناء المضلع التكراري التراكمي، فعند أخذ التكرارات التراكمية التي أقل من الحد الأعلى للفئة الفعلية نحصل على أقل من القوس القوطي، وفي حال أخذ التكرارات التراكمية التي أكثر من الحد الأدنى للفئة الفعلية نحصل على أكثر من القوس القوطي.

أخيراً ننوّه إلى أنَّ كلاً من القوسين الناشئين عن تقاطع مضلعي التكراري المتجمع الصاعد والهابط يُدعى **قوساً قوطياً** Ogive تشبيهاً بالقوس القوطي المستخدم في بعض الأبنية القديمة والكاتدرائيات، والشكل الآتي يوضح ذلك.



الشكل (١, ٢٨) القوسين القوطيين الناشئين عن تقاطع مضلعي التكراري المتجمع الصاعد والهابط لبيانات الجدول (١, ١٥)

(١, ٥, ٤) المنحنيات التكرارية Frequency Curves

هي منحنيات تنتج عن المضلعات التكرارية (بأنواعها السابقة) وبطريقة مماثلة تماماً لما تمَّ شرحه في الفقرة (١, ٣, ٥)، ولذلك نادراً ما يستخدم هذا النوع من المنحنيات في المجالات التجريبية (العملية).

(١, ٥, ٥) تمارين

١ - لتكن لدينا البيانات الآتية التي تمثل درجات الاختبار النهائي لـ 99 طالباً في مقرر الإحصاء (الدرجة من 60).

48	40	15	30	27	29	25	37	20	34	56	30	46	46	37	36	26
38	9	0	38	18	29	37	31	27	30	20	32	35	40	21	25	36
38	56	36	40	46	39	21	5	39	32	47	33	34	39	54	51	19
26	47	47	33	32	20	36	20	45	48	36	60	39	36	18	46	38
44	9	45	20	8	40	12	27	46	47	20	46	12	29	57	58	39
4	18	57	49	50	52	39	34	33	34	55	55	35	60			


ولنقم بصب هذه البيانات في جدول توزيع تكراري تكون فيه سعة الفئة الفعلية تساوي $C = 9$ ، ومن ثمَّ لنقم بتقديم العروض البيانية: المدرج التكراري، المضلع التكراري ومضلع التكرار المتجمع.

التنفيذ: إنَّ جدول التوزيع التكراري للبيانات المُعطاة له العرض الآتي في الجدول (١٧, ١):

الجدول (١٧, ١)

رقم الفئة	حدود الفعلية للفئة	مركز الفئة	تكرار الفئة	التكرار المتجمّع الهابط للفئة
1	0 → 9	4.5	4	4
2	9 → 18	13.5	5	9
3	18 → 27	22.5	16	25
4	27 → 36	31.5	22	47
5	36 → 45	40.5	24	71
6	45 → 54	49.5	18	89
7	54 → 63	58.5	10	99
Total	-----	----	99	-----

ومن ثمَّ يكون للمدرج والمضلع التكراري لبيانات الجدول السابق العرض الآتي:



الشكل (١٧, ٢٩)


لقد ذكرنا سابقاً أنَّ بعض المراجع تغلق المضلع التكراري إلى طرفي الفئة الأولى والأخيرة وهذا يوافق حالة مثالنا هذا، إذَّ إنه لا توجد درجة اختبار طالب دون الصفر ولا أكبر من 60، فيجوز في مثل هذه الحالة الإغلاق إلى بداية الفئة الأولى ونهاية الفئة الأخيرة (أو إلى القيمة 60)، فيصبح للمضلع التكراري السابق العرض الآتي:



الشكل (١٧, ٢٩) ب

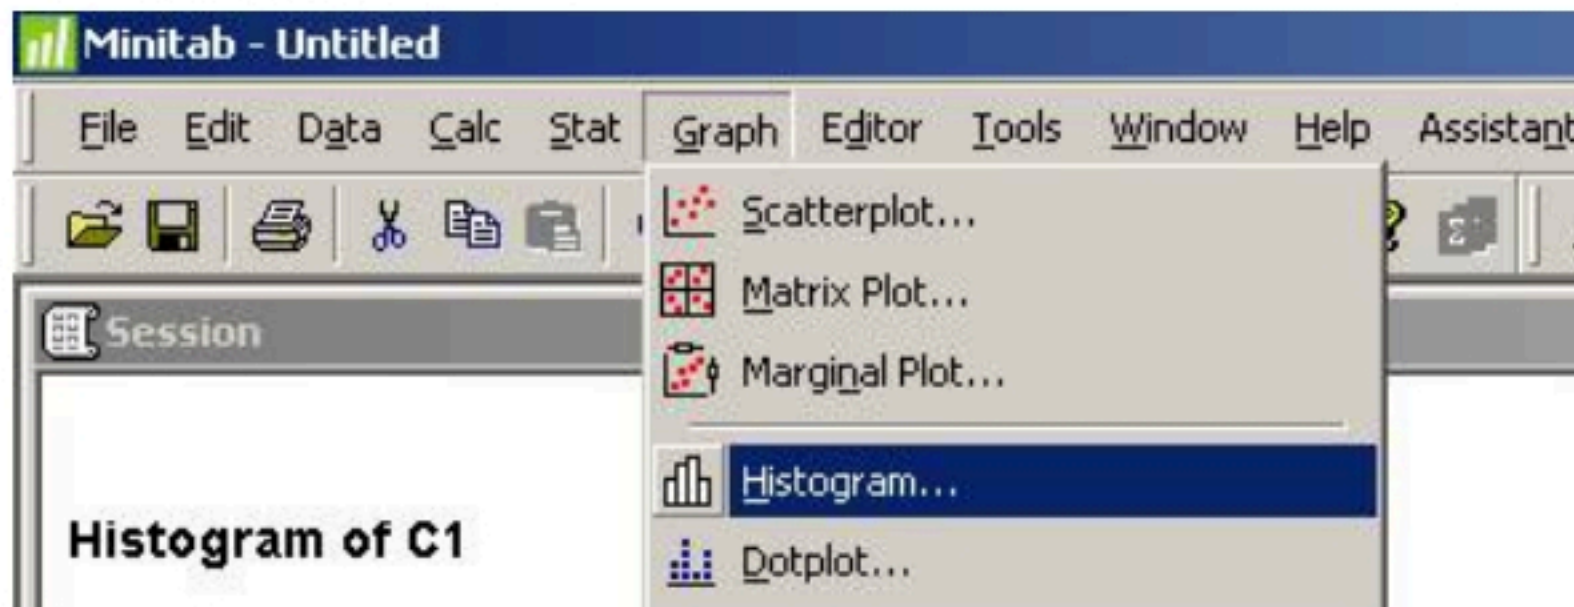
وأخيراً يكون لمضلع التكرار المتجمّع الصاعد العرض الآتي:

AF (Ascending Frequency)




الشكل (٢٩، ١ ج)

ومن الممكن إنجاز المدرج التكراري لبيانات جدول توزيع تكراري باستخدام برنامج Minitab من فقرة Graph في شريط الأوامر ومن ثم اختيار Histogram.



فعلى سبيل المثال للحصول على المدرج التكراري لمجموعة بيانات التمرين / ١ / من (١, ٥, ٥) دون استخدام جدول التوزيع التكراري وعلى أن نحدد له عدد الفئات والتكرارات وتنفيذ بعض الإعدادات اللازمة (التي تحتاج إلى خبرة في عمل هذه البرنامج حيث لا مجال هنا لشرحها)، فنحصل على العرض الآتي للمدرج التكراري:



الشكل (٢٦، ١ د). المدرج التكراري لبيانات الجدول (١، ١٧)

٢- لتكن لدينا مجموعة البيانات الآتية التي تمثل الطول لـ 68 نبتة قمح في مختبر زراعي (مقدرة بالمليمتر) وذلك بعد شهرين

168 159 172 171 189 180 152 195 185 165 167 170 155 173 194
188 185 172 199 152 186 170 167 208 167 153 168 179 177 171
186 167 193 165 150 172 195 140 173 169 180 187 184 175 167
181 184 170 160 169 155 166 190 200 173 203 160 145 171 177
181 191 182 172 196 179 154 148

ولنقم بصب هذه البيانات في جدول توزيع تكراري فيه عدد الفئات $k = 7$ ، فنجد أن السعة لكل فئة فعلية من فئاته تساوي:


$C = (R + 1) / k = 69 / 7 = 9.86$

ولجعل عملية الصب أكثر سهولة ويسراً سنقرب قيمة السعة إلى العدد 10، فيكون لجدول التوزيع التكراري المطلوب العرض الآتي:

الجدول (١٨، ١)

رقم الفئة	لحدود الفعلية للفئة	مركز الفئة	تكرار الفئة	التكرار المتجمع الهابط للفئة
1	140 → 150	145	3	3
2	150 → 160	155	8	11
3	160 → 170	165	14	25
4	170 → 180	175	18	43
5	180 → 190	185	14	57
6	190 → 200	195	8	65
7	200 → 210	205	3	68
Total	-----	-----	68	-----


فعندئذ نجد للمدرج والمضلع التكراري لبيانات هذا الجدول العرض المقدمة من خلال الشكل الآتي:



الشكل (٢٧، ١.١)

وأخيراً يكون لمضلع التكرار المتجمع الصاعد الشكل الآتي:

AF (Ascending Frequency)



الشكل (٢٧، ١.ب)

٣- لتكن لدينا مجموعة البيانات الآتية التي تمثل عدد جلسات علاج فيزيائي تلقاها 81 مريضاً حتى استكمال الاستشفاء.


11 24 6 9 30 7 13 26 20 30 20 11 14 6 9 29
 23 15 26 8 17 18 23 12 11 28 26 28 15 30 10 10
 22 32 5 16 25 7 22 20 12 13 25 24 5 28 20 27
 9 20 14 15 21 21 27 27 8 24 18 5 26 14 11 21
 22 10 32 27 27 17 20 24 18 29 30 26 31 26 10 11 25

ف نجد أن العدد الافتراضي للفئات $k = \lceil 6.34 \rceil = 7$ ، وأما المدى للبيانات فإنه يساوي $R = 27$ ، ومن ثم تكون القيمة الافتراضية لسعة كل فئة هي $C = 4$ ، وبالتالي سيكون للجدول التكراري المطلوب العرض الآتي:


الجدول (١٩، ١)

رقم الفئة	لحدود الفعلية للفئة	مركز الفئة	تكرار الفئة	التكرار المتجمع الهابط للفئة
1	05 → 09	7	9	9
2	09 → 13	11	14	23
3	13 → 17	15	9	32
4	17 → 21	19	11	43
5	21 → 25	23	12	55
6	25 → 29	27	17	72
7	29 → 33	31	9	81
Total	-----	-----	68	-----

فعندئذ نجد للمدرج والمضلع التكراري لبيانات هذا الجدول العرض المقدمة من خلال الشكل الآتي:



وأخيراً يكون لمضلع التكرار المتجمع الصاعد الشكل الآتي:



١,٦ أشكال التوزيعات التكرارية

Forms of Frequency Distributions

لاحظنا من خلال الأمثلة السابقة أن التوزيعات التكرارية لها أشكال مختلفة ومتباينة، ولهذا وجب تصنيف هذه التوزيعات لتسهيل التعامل مع مسمياتها وتصورها ذهنياً من مجرد معرفة نوعها، ولقد درجت العادة على تصنيف التوزيعات التكرارية من شكل التوزيع إلى نوعين رئيسيين:

١, ٦, ١ التوزيعات التكرارية المتناظرة Symmetric Frequency Distributions:


إن الصفة التي تميز هذه التوزيعات هي تناظر شكلها بالنسبة إلى محور مار من قمة التوزيع، وهذا النوع من التوزيعات يقسم بدوره إلى نموذجين هما:

١ - التوزيعات المتناظرة أحادية المنوال Unimodal Symmetric Distributions:

التوزيعات المتناظرة الأحادية المنوال هي تلك التوزيعات التي يكون لشكلها البياني قمة وحيدة، ومن أجل هذه التوزيعات يمكننا التمييز بين ثلاثة أنواع هي:

- أ - توزيعات مدببة Leptokurtic ب - توزيعات معتدلة Mesokurtic ج - توزيعات منبسطة Platykurtic.
- علماً أن مفهوم الاعتدال للتوزيعات بُني على مدى تقارب شكله من شكل دالة الكثافة للتوزيع الطبيعي المعياري، حيث لمعامل

التفليطح (سنأتي على ذكره في نهاية الفصل الثاني) للتوزيع الطبيعي المعياري قيمة تساوي الصفر، ولذلك أخذ شكل دالة الكثافة الاحتمالية للتوزيع الطبيعي المعياري على أنه شكل معتدل تُقاس عليه بقية التوزيعات (سنأتي على ذكر دالة الكثافة للتوزيع الطبيعي المعياري في الفصل السادس، والشكل الآتي للتوزيع المعتدل يمثل رسمها البياني).




الشكل (٢٩، ١).

وأما للحكم على تدبب أو تفليطح توزيع ما فإننا نحتاج لمعيار محدد سنأتي على ذكره لدى تقديم المقاييس العددية لأشكال التوزيعات في الفصل القادم.

لاحظ أن مجموعة بيانات التمرين ٢ / من (١, ٥, ٥) السابقة تقدم لنا مثالاً على هذا النوع من التوزيعات، حيث يلاحظ التناظر لشكل المدرج التكراري وكذلك لشكل المضلع التكراري لتلك البيانات.

٢- التوزيعات المتناظرة متعددة المناويل Multimodal Symmetric Distributions

تتميز هذه الأنواع من التوزيعات بأنها تمتلك قيمتين على الأقل، والنموذجان الآتيان يوضحان لنا بعضاً منها:



الشكل (٣٠، ١).

إن مجموعة بيانات التمرين ٣ / من (١, ٥, ٥) السابقة تقدم لنا مثالاً على توزيع تكراري ثنائي المنوال حيث يلاحظ وجود قيمتين لشكل المدرج التكراري وكذلك لشكل المضلع التكراري لتلك البيانات، ولكنه ليس متناظراً.

(١, ٦, ٢) التوزيعات التكرارية الملتوية Skewed Frequency Distributions

وهذه التوزيعات التكرارية لا تُحقق خاصية التناظر بالنسبة إلى محور مار من قمة التوزيع في حال التوزيعات الأحادية المنوال، وفي حال التوزيعات المتعددة المناويل يكون شكل التوزيع غير متناظر بالنسبة إلى محور مار من منتصف قاعدة التوزيع (أي إنها توزيعات غير متناظرة Non Symmetric Distributions)، ويقسم هذا النوع من التوزيعات إلى صنفين رئيسيين هما:

١- التوزيعات الملتوية نحو اليمين (أو موجبة الالتواء) Skewed to the Right (or Positive Skewed) Distributions

إن أشكال هذه التوزيعات تتميز بظهور ذيل طويل ممتد نحو اليمين أكثر من ذلك الذي يمتد نحو اليسار، والشكل الآتي يوضح ذلك من أجل توزيع وحيد المنوال.



الشكل (١, ٣١)

٢- التوزيعات الملتوية نحو اليسار (أو سالبة الالتواء) **Skewed to the Left (or Negative Skewed) Distributions** إن أشكال هذه التوزيعات تتميز بظهور ذيل طويل ممتد نحو اليسار أكثر من ذلك الذي يمتد نحو اليمين، والشكل الآتي يوضح ذلك من أجل توزيع وحيد المنوال.



الشكل (١, ٣٢)

إن مجموعة بيانات التمرين ١ / ١ من (٥, ٥, ١) السابقة تقدم لنا مثلاً على بيانات لها توزيع ملتو نحو اليسار، حيث يلاحظ الالتواء لشكل المدرج التكراري وكذلك لشكل المضلع التكراري لتلك البيانات. إن كيفية الحكم على التواء التوزيع يحتاج إلى معايير محددة سنأتي على ذكرها في الفصل القادم.

(١, ٦, ٣) تفسير شكل التوزيع:

في الواقع يمكن تقديم بعض التفسيرات لأشكال التوزيعات، ومنها:

١- إذا كان للتوزيع التكراري شكل متناظر معتدل فإن ذلك يعني أن البيانات تتوزع طبيعياً على وجه التقريب، وأن الأخطاء المرتكبة لدى عملية القياس هي على الغالب أخطاء عشوائية (غير متعمدة).

٢- إذا كان للتوزيع التكراري عدة مناويل فإن ذلك يدل على وجود عدة أسباب فاعلة ومؤثرة في التجربة (أو المسألة) المولدة للبيانات، وعادة يكون عدد هذه الأسباب الفاعلة والمؤثرة مساوياً لعدد المناويل في التوزيع.

٣- إذا كان للتوزيع التكراري شكل ملتو نحو اليمين فإن ذلك يعني على الغالب تنفيذ عمليات فرز بشأن البيانات بحيث يستثنى منها البيانات التي تقل عن مقدار محدد تفرضه طبيعة الدراسة الإحصائية، وأما إذا كان شكل التوزيع ملتو نحو اليسار فإن ذلك يعني على الغالب تنفيذ عمليات فرز بشأن البيانات بحيث يستثنى منها البيانات التي تزيد عن مقدار محدد تفرضه طبيعة الدراسة الإحصائية.

٤- إذا كان شكل التوزيع التكراري منبسطاً فإن ذلك يعني على الغالب تنفيذ عمليات فرز بشأن البيانات بحيث يستثنى منها البيانات التي تقل وتزيد عن قيمة محددة تفرضها طبيعة الدراسة الإحصائية، وكذلك يدل على أن البيانات تتبعثر بعيداً عن قيمة المتوسط لهذه البيانات وذلك تبعاً لمقدار تفرطح هذا التوزيع.

هذا ما تيسر تقديمه من أجل الجزء النظري والتطبيقي لهذا الفصل

تمارين الفصل الأول

١- صنف المتغيرات الآتية وفقاً لكافة المعايير التي درستها في هذا الفصل مع تعيين مجموعة قيمها إن أمكن ذلك (يمكنك استخدام افتراضات مناسبة عند الضرورة):

- أ- درجة الطالب في الاختبار الأخير لمقرر دراسي.
- ب- الحرارة (مقدرة بالدرجة المتوية Celsius) داخل ثلاجة منزلية.
- ج- أعمار الطلاب (مقدراً بالسنوات) في جامعة ما.
- د- الزمن اللازم للوصول إلى العمل إذا كنت قد انطلقت من المنزل.
- هـ- عدد الكواكب السيارة التي تدور حول النجوم في مجرة ما.
- و- أطوال الطلاب في جامعة ما.
- ز- عدد المقررات الدراسية لطالب يدرس في جامعة ما.
- ح- أوزان الماشية في مزرعة لتسمين الأغنام.
- ط- أرقام البطاقات الشخصية للمواطنين في بلد ما.
- ي- عدد مرّات قذف قطعة نقود معدنية حتى الحصول على صورة لأول مرّة.
- ك- عدد الحوادث المرورية التي تقع على طريق سريع خلال شهر معيّن من السنة.
- ل- أعمار (مقدرة بالساعة) الأطفال حديثي الولادة (الحُدَج) في مستشفى للتوليد.
- م - الحرارة (مقدرة بالكلفن Kelvin) داخل جهاز تبريد ذي قدرة عالية جداً على التبريد (يمكنه الوصول إلى الصفر المطلق ولو نظرياً).
- ن- الحالات الجنائية في المحاكم.
- ص- الألوان الناتجة عن تحليل الضوء الأبيض.

٢- صنف البيانات الناتجة عن المتغيرات في السؤال السابق وفقاً للمقاييس التي درستها في هذا الفصل مع مناقشة حالة الصفر ودلالته إن وجد.

٣- البيانات الآتية (كل قيمة مكوّنة من ثلاثة أرقام) تمثّل قوة الضغط (مقدّرة بالرطل على البوصة) لعينة مكوّنة من 78 سبيكة معدنية لاستخدامها في تصنيع الدوائر المتكاملة.

123	134	178	76	167	184	105	229	146	218	157	101
171	105	221	183	186	121	181	180	143	97	154	153
174	120	104	115	160	208	158	133	207	180	190	93
194	133	156	168	167	141	245	208	74	199	181	158

والمطلوب صب هذه البيانات في جدول الساق والأوراق.

٤- الجدول الآتي يعرض لنا قيمة المبيعات في مؤسسة خلال الأعوام 2005-2012 مقدّرة بـ مليون ريال سعودي، والمطلوب تقديم العروض البيانية المختلفة (الأعمدة - الخطوط المنكسرة - الدائرة) لبيانات هذا الجدول.

Year	2012	2011	2010	2009	2008	2007	2006	2005	العام
Amount	180	145	250	210	175	100	200	150	المبلغ

٥- سُئل طلاب (عددهم 30) في كلية إدارة الأعمال عن تخصصاتهم، فكانت ردودهم كما يأتي:

A	M	M	A	M	M	E	M	O	A
E	E	M	A	O	E	M	A	M	A
M	A	O	A	M	E	E	M	A	M

علماً أنَّ M تعني إدارة، وA تعني المحاسبة، وE تعني اقتصاداً، وأخيراً O تعني اختصاصاً آخر. عندئذ المطلوب بناء الجدول التكراري ومن ثمّ تقديم العرض الشرائطي والدائري لهذه البيانات.

٦- طلب من 20 شخصاً من نزلاء فندق أن يدونوا مستوى الخدمة المقدّمة لهم في هذا الفندق وذلك بكتابة إحدى العبارات الآتية: ممتازة Excellent، جيدة Good، متوسطة Average، ما دون المتوسطة Below Average أو ضعيفة Poor، فكانت نتائج إجاباتهم كما في الجدول الآتي:

Below Average	Good	Average	Average	Poor
Good	Average	Average	Average	Good
Average	Good	Good	Average	Below Average
Good	Poor	Excellent	Excellent	Poor

والمطلوب بناء الجدول التكراري لهذه البيانات، ومن ثمّ تقديم العروض البيانية المختلفة (الأعمدة - الخطوط المنكسرة - الدائرة) الموافقة لهذه البيانات.

٧- لنفترض أنّه لدينا مجموعة من البيانات (لتقديرات A، B، C وD) مقدّمة من خلال العرض البياني الآتي (العرض باستخدام الأعمدة)، والمطلوب تقديم العروض البيانية المختلفة الأخرى (الجدول - الخطوط المنكسرة - الدائرة) لبيانات هذا العرض.



٨- لتكن لدينا مجموعة من البيانات مقدّمة من خلال الجدول التكراري الآتي:

رقم الفئة	الحدود الفعلية للفئة	مركز الفئة	تكرار الفئة	التكرار النسبي للفئة	التكرار المئوي للفئة	التكرار المتجمّع الصاعد للفئة	التكرار المتجمّع الهابط للفئة
1	14 → 17		3				90
2	17 → 20			0.2111			
3	20 → 23				13.33%		
4	23 → 26					59	
5	26 → 29				16.67%		
6	29 → 32		16	0.1777			
Total							المجموع

والمطلوب ما يلي:

أ- أكمل معطيات هذا الجدول.


ب- قدّم جميع العروض البيانية التي درستها في هذا الفصل لتمثيل بيانات هذا الجدول.

٩- لدينا مجموعة من البيانات مكونة من 180 مشاهدة، ومقدمة من خلال زوايا القطاعات الدائرية للقرص الدائري، حيث كانت قيم هذه الزوايا كما يلي:


الفئة	A	B	C	D	E
الزاوية المخصصة لها	36	54	90	162	18

والمطلوب رسم القرص الدائري للبيانات، ومن ثمّ تقديم الجدول التكراري لهذه البيانات، وبعد ذلك رسم العرض الشرائطي والخطوط المنكسرة الموافقة لهذا العرض.

١٠- لدينا مجموعة من البيانات مقدمة من خلال مضلع التكرار المتجمّع الصاعد الآتي:



والمطلوب تقديم العروض البيانية المختلفة الأخرى (جدول التوزيع التكراري، المدرج التكراري، المضلع التكراري ومضلع التكرار المتجمّع الهابط) لبيانات هذا الجدول.



١١- لدينا مجموعة بيانات مقدمة من خلال القرص الدائري الآتي:

فإذا علمت أنّ المجموع الكلي للبيانات يساوي 720 قيمة، فعندئذ المطلوب تقديم الجدول التكراري لهذه البيانات، ومن ثمّ رسم العرض الشرائطي والخطوط المنكسرة الموافقة لهذا العرض.


١٢- لتكن لدينا مجموعة من البيانات الخام معطاة كما يلي:

64	77	92	73	64	84	63	74	64	69	60	79	66	76
80	62	73	74	92	75	82	61	65	84	75	81	71	77
84	77	62	68	75	83	64	58	69	67	91	64	77	92
73	64	84	63	74	64	69	99	61	68	74	66	69	76

والمطلوب ما يلي:

- أ- صبّ (أو تفرغ) هذه البيانات السابقة في جدول توزيع تكراري يحوي الأعمدة الأساسية فقط.
- ب- ارسم المدرج والمضلع التكراري ومضلع التكرار المتجمع الصاعد لبيانات جدول التوزيع التكراري الناتج في الطلب السابق، ومن ثم ناقش شكل التوزيع الناتج.
- ١٣- لنفترض أنه لدينا مجموعة بيانات مقدّمة من خلال المدرج التكراري الآتي:


Percentile Frequency %



والمطلوب تقديم جدول التوزيع التكراري لهذه البيانات، ومن ثم رسم المضلع التكراري، والمضلع التكراري النسبي، ومضلع التكرار المتجمع الصاعد لبيانات الجدول الناتج.

- ١٤- لنفترض أنه لدينا مجموعة بيانات مقدّمة من خلال المضلع التكراري الآتي:

Frequency



والمطلوب تقديم جدول التوزيع التكراري لهذه البيانات، ومن ثم رسم المدرج التكراري، والمدرج التكراري النسبي، والمدرج التكراري المثنوي، ومضلع التكرار المتجمع الصاعد والهابط لبيانات الجدول الناتج.

الفصل الثاني

المقاييس الوصفية للبيانات

DESCRIPTIVE MEASURES OF DATA

تمهيد

لقد ناقشنا في الفصل السابق بعض الطرائق المستخدمة في عرض البيانات ولاحظنا أهميتها عند تقديم المعلومات، فهي تُعطي وصفاً عاماً وسريعاً للبيانات. إلا أن فوائدها الاستقرائية قليلة، فالمضلع التكراري لبيانات عينة أُخذت من المجتمع يُعطينا تصوراً عن شكل المضلع التكراري لمجتمع هذه البيانات، واستقراؤنا له يقف عند الفرض بأنه يوجد تشابه ما بين المضلع الممثل لبيانات هذه العينة والمضلع الممثل لبيانات المجتمع الأصل، ومن ثم المشكلة التي نقف عندها هي كيفية قياس درجة الاختلاف بينهما. إن اعتماد المقارنة للأشكال فقط وباستخدام النظر قد لا يُعطينا الاستقراء الدقيق، وفي حال كان دقيقاً إلى حد ما فإن ذلك يختلف من شخص إلى آخر حيث تصبح الدقة هنا مفهوماً نسبياً. لهذا السبب يُفضل وجود مقاييس كمية تُمكننا من التعرف بشكل جيد على الخصائص والسلوك للتوزيع التكراري الخاص بالمجتمع المدروس. لذلك سوف نوجه اهتمامنا فيما يلي إلى تعيين قيمة أو أكثر من أجل مجموعة البيانات التي يُستدل من خلالها على حقائق وخصائص الظاهرة التي تمثلها مجموعة البيانات ككل، وهذا يتطلب منا ما يلي:

أولاً: البحث عن قيمة عددية (أو قيم عددية) تنزع إليها البيانات (بمعنى أن هذه القيمة - أو القيم - تبدو وكأنها نقطة جذب للبيانات)، وتُدعى مثل هذه القيم العددية **مقياساً للنزعة المركزية** Central Tendency Measure، وفي حال وحدانية هذه القيمة من أجل مجموعة بيانات محدّدة فإنه يُقال عنها إنها قيمة وسطى لهذه البيانات.

تجدر الإشارة هنا إلى أن القيم العددية الناتجة عن مقاييس النزعة المركزية تندرج تحت مفهوم **مقاييس الموضع** للبيانات Position Measures of Data.

ثانياً: البحث عن قيمة عددية تُعبّر عن مدى تشتّت (أو تبعثر) قيم البيانات حول مقياس نزعتها المركزية (أو قيمتها الوسطى)، ويُدعى هذا العدد **مقياساً للتشتّت** Dispersion Measure.

ثالثاً: البحث عن قيمة عددية تُشير إلى شكل التوزيع للبيانات أو مظهره كما سبق وأوضحنا ذلك في الفصل الأول، وهنا نهتم بمعيّارين لشكل التوزيع هما:

المعيار الأول: يتعلّق بتناظر شكل التوزيع من عدمه، أي الإجابة على السؤال الآتي:

هل شكل التوزيع متناظر أم إنه ملتو (نحو اليمين أم نحو اليسار)؟

إن القيم العددية التي تُعبّر عن هذه الخصائص لشكل التوزيع تندرج تحت اسم **مقاييس الالتواء** Skewness Measures.

المعيار الثاني: يتعلّق بارتفاع وانخفاض قمة شكل التوزيع، أي الإجابة على السؤال الآتي:

هل التوزيع مديباً، مفلطحاً أم معتدلاً؟

إنَّ القيم العددية التي تعبّر عن هذه الخصائص لشكل التوزيع تندرج تحت اسم **مقاييس التفلطح** (أو التفرطح) Kurtosis Measures.

يوجد في الواقع أنواع أخرى من المقاييس التي تساعدنا في عملية الاستقراء لنتائج البيانات، إلا أنَّها أقل أهمية من المقاييس السابقة. لذلك سنبدأ بتقديم شرح مفصّل حول المقاييس التي نوهنا بها آنفاً، ومبتدئين بمقاييس النّزعة المركزية. إنَّ مقاييس النّزعة المركزية تعدّ من أهم مقاييس الموضع، ولو أنَّ لمقاييس الموضع الأخرى (مثل الرُّبُعيّات **Quartiles** والمئينات **Percentiles**) عمل مهم أيضاً ولكنه مختلف بعض الشيء عن عمل مقاييس النّزعة المركزية، ولهذا السبب سنقدّم مقاييس النّزعة المركزية أولاً ومن ثمّ الرُّبُعيّات والمئينات (وسوف نتجاوز مفهوم العُشيرات **Deciles** بسبب قلة استخدامه).

(٢, ١) مقاييس النّزعة المركزية

Central Tendency Measures


من المهام الأساسية في العديد من التحليلات الإحصائية عملية تقدير **مَعْلَمَة** Parameter الموضع لتمرکز التوزيع (مَعْلَمَة تجمع على "مَعْلَم"، وتُعرف في بعض المراجع العربية باسم "وسيط" أيضاً، وتجمع على "وسطاء"). إنَّ عبارة "النّزعة المركزية" في إطار الدراسات الإحصائية تعني نزوع مجموعة قيم البيانات (أو مجموعة جزئية منها) نحو قيمة نموذجية أو مركزية تمثّلها (أو تمثّل هذه المجموعة الجزئية من البيانات)، وفي حال وحدانية هذه القيمة التي تنزع إليها البيانات فإنّها تُمثّل مفهوم مركز الثقل لجسم صلب في الميكانيكا، ولذلك فإنَّ عبارة النّزعة المركزية تتعلّق بالطريقة التي تميل بها البيانات إلى التجمّع حول قيمة ما (أو التكاثر حول مركز ثقلها).

(٢, ١, ١) تعريف (مقياس النّزعة المركزية)

إنَّ أي قيمة عددية (لبيانات كمية) أو رمز (لبيانات نوعية) تنزع إليها البيانات كلياً أو جزئياً تدعى **مقياساً للنّزعة المركزية**. بحسب هذا التعريف يتضح لنا أنّه من أجل مجموعة بيانات مُعطاة قد يكون لدينا أكثر من قيمة ممثّلة للنّزعة المركزية لهذه البيانات، ومفهوم المتوال الذي سيرد ذكره لاحقاً يوضّح لنا معنى ذلك. في عملية التحليل الإحصائي غالباً ما تُستخدم شروط قبل اختيار الشّكل الأوّلي للتحليل الإحصائي، ومنها على سبيل المثال: ماذا تعني كلمة القيمة النموذجية الممثّلة للبيانات؟ لذلك فإنَّ الهدف الأوّلي قد يكون اختيار المقياس المناسب للنّزعة المركزية الذي يُعطينا دلالة واضحة لما تعنيه القيمة النموذجية الممثّلة للبيانات. علماً أنَّ البيانات التي سنستخدمها في هذا الفصل والفصل الذي يليه هي بيانات وحيدة البعد، أي إنّها بيانات ناتجة عن متغيّر وحيد البعد، بمعنى أنّه في إطار دراستنا هذه ستكون البيانات من الشكل x_1, x_2, \dots, x_n وليست على شكل ثنائيات (x, y) أو ثلاثيات (x, y, z) أو.... سنقدّم فيما يلي العديد من مقاييس النّزعة المركزية، والمقياس الآتي يُعدّ من أشهره.

(٢, ١, ٢) المتوسط **Mean** (أو المتوسط الحسابي **Arithmetic Mean**)

إنَّ خير ما يوضّح مفهوم المتوسط لمجموعة قيم عددية هو مركز الثقل لقضيب (ليس بالضرورة أن يكون متجانساً) يوضع على حامل. إنَّ مفهوم مركز الثقل لجملة مادية في الميكانيكا يُعرّف مركز الثقل لجسم صلب على أنّه تلك النقطة من الجسم التي يكون فيها مجموع العزوم بالنسبة لها يساوي الصفر وذلك عند وضع هذا الجسم في حقل قوى متوازي (انظر الرسم التوضيحي الآتي). فلو نظرنا إلى كل نقطة من هذا القضيب على أنّها قيمة عددية (تعبّر عن كتلة تلك النقطة)، فعندئذ مركز ثقل هذا القضيب (النقطة التي يتوازن عنها القضيب) هي قيمة المتوسط لهذه القيم. بالطبع لو كان القضيب متجانساً فعندئذ يكون مركز ثقله واقعاً على نقطة المنتصف للقضيب. لاحظ من هذا المفهوم يتضح لنا أن المجموع الجبري لانحرافات النقاط (القيم) عن مركز ثقلها (متوسطها) سيكون مساوياً للصفر.



الشكل (١، ٢)

الآن، ومن أجل تعريف المتوسط (ويعرف باسم "المتوسط الحسابي" **Arithmetic mean** أيضاً) الذي يُرمز له بـ \bar{x} من أجل العينات و μ من أجل المجتمعات، سنناقش الحالتين الآتيتين:

أولاً: من أجل البيانات الخام **Raw Data**، سنميز بين حالتين هما:

أ - إذا كانت x_1, x_2, \dots, x_n بيانات لعينة، علماً أنّ $n \in N$ كافي ولكن مُثبت، فعندئذ يحسب المتوسط لهذه البيانات يُحسب باستخدام العلاقة الآتية:

$$\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n} = \frac{1}{n} \sum_{i=1}^n x_i \quad [2,1-a]$$

ب - إذا كانت x_1, x_2, \dots, x_N بيانات لمجتمع إحصائي، فإنّ المتوسط لهذه البيانات يُحسب باستخدام العلاقة الآتية:

$$\mu = \frac{x_1 + x_2 + \dots + x_N}{N} = \frac{1}{N} \sum_{i=1}^N x_i \quad [2,1-b]$$

ثانياً: من أجل البيانات المُجمّعة **Grouped Data**:

بفرض أنّه لدينا بيانات مجمّعة مُعطاة في جدول توزيع التكراري (أو جدول تكراري حيث يكون لدينا ذات الجدول ولكن بدون عمود الفئات فقط، وبدلاً من مراكز الفئات يكون لدينا ممثلي البيانات بعد ترتيبها تصاعدياً، ورقم الفئة هو رقم الممثل) كالآتي:

الجدول (١، ٢)

رقم الفئة	لحدود الفعلية للفئة	مركز الفئة	تكرار الفئة	التكرار المتجمّع الصاعد للفئة
1	$b_0 \rightarrow b_1$	x_1	f_1	$F_1 = f_1$
2	$b_1 \rightarrow b_2$	x_2	f_2	$F_2 = f_1 + f_2$
\vdots	$\vdots \vdots \vdots$	\vdots	\vdots	$\vdots \vdots \vdots$
$k-1$	$b_{k-2} \rightarrow b_{k-1}$	x_{k-1}	f_{k-1}	$F_{k-1} = f_1 + f_2 + \dots + f_{k-1}$
k	$b_{k-1} \rightarrow b_k$	x_k	f_k	$F_k = f_1 + f_2 + \dots + f_{k-1} + f_k$
Total	-----	-----	$\sum f_i$	-----

علماً أنّنا كتبنا $\sum f_i$ بدلاً من $\sum_{i=1}^k f_i$ على سبيل التبسيط، فعندئذ إذا كانت البيانات لعينة بمجموع تكرارات $\sum f_i = n$ (أو لمجتمع بمجموع تكرارات $\sum f_i = N$)، فإنّ المتوسط لبيانات الجدول (سواء كان جدول تكراري أو جدول توزيع تكراري) تُحسب كما يلي على الترتيب:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^k f_i \cdot x_i \quad \text{for sample} \quad [2,2-a]$$

$$\mu = \frac{1}{N} \sum_{i=1}^k f_i \cdot x_i \quad \text{for population} \quad [2,2-b]$$

علماً أنَّ x_i و f_i هو مركز وتكرار الفئة ذات الرقم i على الترتيب. نلاحظ هنا أنَّه من أجل الجداول التكرارية ستكون قيمة المتوسط تساوي قيمة متوسط البيانات الخام نفسها دوماً، ولذلك سوف لن ندرج أمثلةً على حسابها من أجل هذا المقياس.

(١, ٢, ١, ٢) أمثلة

١- لتكن لدينا البيانات الخام الآتية (١٣٢ مشاهدة) والممثّلة لأطوال طلاب في مدرسة ثانوية (هنا المدرسة لها دور المجتمع) مقدّرة بالسنتيمتر.

172	167	178	196	188	154	171	181	188	169	149	195
167	157	169	175	193	189	167	192	178	182	160	175
172	173	173	173	179	193	157	152	173	160	172	168
175	168	179	173	183	169	195	181	178	190	158	190
175	169	172	173	160	173	168	172	172	158	163	169
170	178	172	172	170	183	189	167	184	173	181	177
169	165	185	175	173	180	193	163	172	149	172	178
173	155	175	175	173	163	171	172	173	171	160	163
173	182	147	179	160	177	175	180	179	160	192	169
179	173	171	171	178	175	173	169	171	170	189	185
170	169	168	158	171	179	152	147	180	173	163	171

عندئذ نجد أنَّ قيمة متوسط الطول لطلاب المدرسة يساوي:

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i = \frac{1}{132} \sum_{i=1}^{132} x_i = \frac{22812}{132} = 172.82$$

وبسحب عيّنة عشوائية بسيطة بحجم $n = 20$ مستخدمين في ذلك برنامج Minitab نجد أنَّ لهذه العيّنة العرض الآتي:

175	169	169	147	163	173	182	189	181	178
172	173	177	173	181	178	193	173	179	175

Length.o.S	Sample-20
172	175
169	169
167	169
173	147
175	163
190	173
168	182
172	189
169	181
149	178
171	179
179	175
179	172
170	173

Sample From Columns

C1 Length.o.S
C2 Sample-20
C3 Sample-50

Number of rows to sample: 20
From columns: 'Sample-20'
Store samples in: C2
☐ Sample with replacement

Select

Help

OK

ومن ثم نجد قيمة المتوسط لبيانات هذه العينة تساوي:

$$\bar{x} = \frac{1}{20} \sum_{i=1}^{20} x_i = \frac{3500}{20} = 175$$

وبسحب عينة عشوائية أخرى من هذه البيانات بحجم $n = 40$ مستخدمين في ذلك برنامج Minitab فنجد لها العرض الآتي:

163	157	178	158	180	173	173	172	170	169
163	177	178	160	169	183	163	172	193	173
172	171	167	160	178	172	157	181	160	170
170	182	169	172	195	188	173	189	169	178

وأما قيمة المتوسط لبيانات هذه العينة فنجدها تساوي:

$$\bar{x} = \frac{1}{40} \sum_{i=1}^{40} x_i = \frac{6897}{40} = 172.43$$

فلاحظ هنا أن قيمة المتوسط للعينات العشوائية ليس بالضرورة أن تتطابق مع قيمة المتوسط للمجتمع وإنما هي قيم تقديرية لقيمة متوسط المجتمع، وسوف نرى فيما بعد (في الفصل التاسع) أنه كلما كبر حجم العينة أكثر فأكثر فإن قيمة متوسطها تقترب أكثر فأكثر من قيمة متوسط المجتمع أيضاً.

٢- قيس الضغط الانقباضي للقلب (في عملية قياس ضغط الدم مقدرة بـ mmHg ميليمتر زئبقي) لعينة مكونة من خمسين شخصاً مصاباً بارتفاع ضغط الدم، فكانت النتائج كما يلي:

157	182	179	168	160	185	175	169	175	166
190	184	182	140	182	199	175	184	176	162
162	160	175	167	179	168	183	191	197	162
177	173	160	171	159	182	168	178	168	172
171	153	166	190	183	174	169	175	160	169

فنجد أن قيمة المتوسط لهذه البيانات (الخام) تساوي:

$$\bar{x} = \frac{1}{50} \sum_{i=1}^{50} x_i = \frac{8652}{50} = 173.04$$

ولنقم بتحميل هذه البيانات في جدول توزيع تكراري بحيث تكون سعة الفئة الفعلية تساوي 10.

العمل: من أجل ذلك نلاحظ أن المدى لهذه البيانات يساوي:

$$\mathcal{R} = x_{\ell} - x_s = 199 - 140 = 59$$

وبالتالي فإن العدد الافتراضي للفئات يساوي $k = \lceil 5.6 \rceil = 6$ ، ومن ثم يكون للبيانات المعطاة جدول التوزيع التكراري الآتي:

الجدول (٢, ٢)

رقم الفئة	لحدود الفعلية للفئة	مركز الفئة x_i	تكرار الفئة f_i	التكرار المتجمع الصاعد للفئة F_i	$x_i \cdot f_i$
1	140 → 150	145	1	1	145
2	150 → 160	155	3	4	465
3	160 → 170	165	17	21	2805
4	170 → 180	175	15	36	2625
5	180 → 190	185	9	45	1665
6	190 → 200	195	5	50	975
Total	-----	----	$\sum f_i = 50$	-----	8680

ومنه قيمة المتوسط لبيانات هذا الجدول تساوي:

$$\bar{x} = \frac{1}{50} \sum_{i=1}^6 f_i \cdot x_i = \frac{8680}{50} = 173.60$$

إنَّ الفرق بين قيمتي المتوسط لكل من البيانات الخام والمجمعة في جدول التوزيع التكراري ناتج عن عملية التجميع للبيانات في فئات، أي بسبب عدم التركيز على القيم المفردة للبيانات والاكتفاء بدور قيم مراكز الفئات كممثل لتجمعات جزئية من هذه البيانات (البيانات التي في الفئات) فقط.

(٢, ١, ٢, ٢) ملاحظات

١- إنَّ الكثير من صيغ العلاقات لها العرض نفسه من أجل بيانات العينة والمجتمع، والخلاف بينهما في رمز حجم العينة n والمجتمع N فقط. لذلك سنقدِّم صيغ العلاقات من أجل بيانات العينات، ونذكر ما يُقابلها من رموز من أجل بيانات المجتمع مع ذكر الصيغة التفصيلية عند الضرورة (أي عندما يكون هناك خلاف في صيغة العلاقة) فقط.

٢- على الرغم من جودة المتوسط، وأنَّه من أهمِّ وأكثر مقاييس النِّزعة المركزيَّة شيوعاً واستخداماً، إلَّا أنَّه يُعاب عليه تأثره بالقيم المتطرفة Extreme Values (أو القيم المنعزلة Outlier Values وسنأتي على تعيين هذه القيم لاحقاً بعد تقديم فقرة الرُّبُعيَّات - انظر الملاحظة ٣/ من (٢, ٢, ٢, ٢))، فعلى سبيل المثال لو قمنا بجمع تبرعات من فصل دراسي لصالح إحدى الجمعيات الخيرية، وكانت لدينا البيانات الآتية مقدَّرة بالريال السعودي:


4	100	5	3	4	5	6	7	4	7
5	5	4	7	5	5	6	7	3	4
1	4	5	4	6	4	7	5	7	1

ف نجد أنَّ القيمة 100 متطرفة (أو منعزلة)، وكذلك نجد أنَّ قيمة متوسط التبرعات لهذا الفصل يساوي 8 ر.س. رغم أنَّ جميع القيم أصغر من 8 باستثناء القيمة 100، فلو قمنا باستثناء القيمة المتطرفة (القيمة 100)، ومن ثمَّ حساب المتوسط لبقية القيم، لوجدنا أنَّها تساوي 4.83 ر.س.، وهي تُعبِّر حقيقة عن القيمة الوسطى لتبرعات مُعظم التلاميذ، وهذا يعني أنَّ القيمة المتطرفة قد جذبت قيمة المتوسط باتجاهها فأعطانا تصوراً غير واقعي حول متوسط تبرعات التلاميذ.

٣- إنَّ المجموع الجبري لانحرافات قيم بيانات خام x_1, x_2, \dots, x_n عن متوسطها \bar{x} يساوي الصفر دوماً، وذلك لأنَّ:

$$\sum_{i=1}^n (x_i - \bar{x}) = \sum_{i=1}^n x_i - \sum_{i=1}^n \bar{x} = \sum_{i=1}^n x_i - n \cdot \bar{x} = n \cdot \bar{x} - n \cdot \bar{x} = 0 \quad [2,3]$$

انظر الرسم التوضيحي الآتي.



الشكل (٢, ٢)

ولتوضيح ذلك حسابياً سنفترض أنَّه لدينا البيانات 1, 3, 5, 6, -5, 3, 9، فنجد أنَّ قيمة المتوسط لهذه البيانات هو $\bar{x} = 3.5$ ، ومن ثَمَّ يكون لدينا:

$$\sum_{i=1}^n (x_i - \bar{x}) = 5.5 - 0.5 + 2.5 + 2.5 - 8.5 + 1.5 - 0.5 - 2.5 = 0$$

(٢, ١, ٣) المتوسط الموزون Weighted Mean

لتكن لدينا بيانات مُعطاة عددها n بحيث إنَّ القيمة x_i تكررت w_i مرَّة من أجل كل $i \in \{1, 2, \dots, r\}$ (نذكرُ هنا إلى أنَّ

رموز مجموعات الأعداد المستخدمة في هذا الكتاب، ورموز أخرى مُدرَّجة، تجدها في بداية الملحق A) مع $\sum_{i=1}^r w_i = n$ ، فعندئذ المتوسط الموزون (أو المرجح) لهذه البيانات يُرمز له بـ \bar{x}_w من أجل العينات (وبـ μ_w من أجل المجتمعات)، يُعرَّف من خلال العلاقة الآتية:

$$\bar{x}_w = \frac{1}{\sum_{i=1}^r w_i} \sum_{i=1}^r w_i \cdot x_i = \frac{1}{n} \sum_{i=1}^r w_i \cdot x_i \quad [2,4-a]$$

$$\mu_w = \frac{1}{\sum_{i=1}^r w_i} \sum_{i=1}^r w_i \cdot x_i = \frac{1}{N} \sum_{i=1}^r w_i \cdot x_i \quad [2,4-b]$$

وفي هذه الحالة تُدعى الأعداد w_1, w_2, \dots, w_r **أوزان البيانات** x_1, x_2, \dots, x_r على الترتيب.

(٢, ١, ٣, ١) ملاحظة

نلاحظ من أجل البيانات المجمعة أنَّ كل فئة من فئات جدول التوزيع التكراري يمكن تمثيلها بمركزها، وأنَّ تكرار هذه الفئة يمثل الوزن لهذا المركز (وبالمثل بالنسبة إلى الجدول التكراري حيث قيمة ممثِّل البيان لها دور مركز الفئة)، ومن ثَمَّ فإنَّ قيمة المتوسط لبيانات جدول توزيع تكراري (جدول تكراري) هي المتوسط الموزون لمراكز فئات (لممثِّل بيانات) ذلك الجدول، فعلى سبيل المثال لو أخذنا البيانات الآتية:

4.0	4.0	2.5	3.0	4.0	9.0	1.5	1.0	9.0	2.5
4.0	3.0	1.5	1.0	9.0	1.5	1.0	3.0	4.0	4.0
1.0	1.5	2.5	3.0	2.5	5.0	1.5	1.5	4.0	2.5

والتي يمكننا عرضها من خلال الجدول التكراري (حيث الوزن w_i يلعب دور التكرار هنا) الآتي:

الجدول (٣, ٢)

<i>i</i>	1	2	3	4	5	6	7	sum
<i>x_i</i>	3	5	1	2.5	4	9	1.5	-----
<i>w_i</i>	4	1	4	5	7	3	6	30
<i>x_i · w_i</i>	12	5	4	12.5	28	27	9	97.5

فعندئذ نجد أنَّ قيمة المتوسط الموزون للبيانات المُعطاة هي:

$$\bar{x}_w = \frac{1}{\sum_{i=1}^7 w_i} \sum_{i=1}^7 w_i \cdot x_i = \frac{97.5}{30} = 3.25$$

٢- بفرض أنَّه لدينا:

\bar{x}_1 هو المتوسط لبيانات $x_{11}, x_{12}, \dots, x_{1n_1}$

\bar{x}_2 هو المتوسط لبيانات $x_{21}, x_{22}, \dots, x_{2n_2}$

.....

\bar{x}_m هو المتوسط لبيانات $x_{m1}, x_{m2}, \dots, x_{mn_m}$

فعندئذ تكون قيمة المتوسط لجميع البيانات السابقة تساوي:

$$\bar{x} = \frac{n_1 \bar{x}_1 + n_2 \bar{x}_2 + \dots + n_m \bar{x}_m}{n_1 + n_2 + \dots + n_m} \tag{2,5}$$

حيث نلاحظ أنَّه يساوي المتوسط الموزون لمتوسطات البيانات المُعطاة بأوزان n_1, n_2, \dots, n_m .

يقدم لنا التعريف الآتي أحد مقاييس التَّزعة المركزيَّة المهمَّة أيضاً (ويستخدم عادةً في مسائل النمو والسرعة).

(٤, ١, ٢) المتوسط الهندسي Geometric Mean

من أجل تعريف المتوسط الهندسي لمجموعة بيانات سنناقش الحالتين الآتيتين، علماً أنَّنا سنرمز له بـ \bar{x}_g من أجل العينات وبـ μ_g من أجل المجتمعات.

١- من أجل البيانات الخام:

لتكن لدينا x_1, x_2, \dots, x_n مجموعة بيانات موجبة تماماً (لعيَّنة أو لمجتمع حيث الفارق هنا رمز الدليل n أو N فقط)، فعندئذ يُعرَّف **المتوسط الهندسي** لهذه البيانات من خلال العلاقة الآتية:

$$\bar{x}_g = \sqrt[n]{x_1 \cdot x_2 \cdot \dots \cdot x_n} \tag{2,6-a}$$

نلاحظ من الصيغة الأخيرة [2-6-a] أنَّه يُفضَّل لحساب المتوسط الهندسي استخدام اللوغاريتمات، وذلك لأنَّه بأخذ لوغاريتم الطرفين للعلاقة الأخيرة نجد ما يلي:

أ- باستخدام اللوغاريتم الطبيعي نجد:

$$\ln \bar{x}_g = \frac{1}{n} \sum_{i=1}^n \ln x_i$$

ومن ثَمَّ ينتج لدينا العلاقة الآتية (والتي يُلاحظ فيها أنَّ الأس هو متوسط القيم $\ln x_1, \ln x_2, \dots, \ln x_n$):

$$\bar{x}_g = \exp \left[\frac{1}{n} \sum_{i=1}^n \ln x_i \right] \quad [2,6-b]$$

ب- باستخدام اللوغاريتم العشري نجد:

$$\log \bar{x}_g = \frac{1}{n} \sum_{i=1}^n \log x_i$$

فنحصل على الصيغة الآتية للمتوسط الهندسي:

$$\bar{x}_g = 10^{\frac{1}{n} \sum_{i=1}^n \log x_i} \quad [2,6-c]$$

حيث نلاحظ أنَّ الأس هو متوسط القيم $\log x_1, \log x_2, \dots, \log x_n$ ، وفي كلا الحالتين يتطلب انجاز الحسابات استخدام حاسبات أو جداول لوغاريتمية.

٢- من أجل البيانات المجمعة:

بفرض أنَّ لدينا بيانات مُجمَّعة في جدول توزيع تكراري (أو جدول تكراري) كما في الجدول (١, ٢) وبمراكز فئات x_1, x_2, \dots و $0 < x_k$ (أو بممثلي x_1, x_2, \dots, x_k و $0 < x_k$)، فعندئذ يُحسب المتوسط الهندسي لبيانات ذلك الجدول من خلال العلاقة الآتية:

$$\bar{x}_g = \sqrt[\sum_{i=1}^k f_i]{x_1^{f_1} \cdot x_2^{f_2} \cdot \dots \cdot x_k^{f_k}} \quad [2,7-a]$$

علماً أنَّ x_i و f_i هو مركز وتكرار الفئة (المثلي للبيانات وتكراراتها المقابلة) ذات الرقم i على الترتيب، ولتبسيط العمليات الحسابية نأخذ لوغاريتم الطرفين للعلاقة الأخيرة فيكون:

$$\ln \bar{x}_g = \frac{1}{\sum_{i=1}^k f_i} \ln \left(\prod_{i=1}^k x_i^{f_i} \right) = \frac{1}{\sum_{i=1}^k f_i} \sum_{i=1}^k \ln x_i^{f_i} = \frac{1}{\sum_{i=1}^k f_i} \sum_{i=1}^k f_i \cdot \ln x_i$$

ومن ثمَّ ينتج لدينا:

$$\bar{x}_g = \exp \left[\frac{1}{\sum_{i=1}^k f_i} \sum_{i=1}^k f_i \cdot \ln x_i \right] \quad [2,7-b]$$

وهنا يُلاحظ أنَّ الأس هو المتوسط للقيم $f_1 \cdot \ln x_1, f_2 \cdot \ln x_2, \dots, f_k \cdot \ln x_k$.

(١, ٤, ١, ٢) ملاحظة

بفرض أنَّ x_1, x_2, \dots, x_r بيانات مُعطاة بأوزان w_1, w_2, \dots, w_r على الترتيب، فعندئذ يُعرف المقدار الآتي:

$$\bar{x}_{g_w} = \sqrt[\sum_{i=1}^r w_i]{x_1^{w_1} \cdot x_2^{w_2} \cdot \dots \cdot x_r^{w_r}} \quad [2,8]$$

باسم **المتوسط الهندسي الموزون** Weighted Geometric Mean، ومن ثمَّ يكون المتوسط الهندسي لبيانات جدول تكراري ذو فئة k هو المتوسط الهندسي الموزون لمراكز فئات هذا الجدول على افتراض أنَّ التكرارات هي أوزان هذه المراكز.

تجدر الإشارة هنا إلى أنَّ المتوسط الهندسي يُستخدم في قطاعات رياضية عديدة منها التحويل والإدارة المالية والإحصاء السكاني.

(٢, ١, ٤, ٢) أمثلة

١- إذا كان مُعدّل التضخّم في بلد ما هو 3 % سنة 2013، وكذلك 4.5 % سنة 2014، وأخيراً 7 % سنة 2015، فعندئذ يُحسب مُعدّل التضخّم للسنوات الثلاث من خلال المتوسط الهندسي لهذه النسب، ويكون لدينا $\bar{x}_g = \sqrt[3]{3 \times 4.5 \times 7} = 4.55$ ، وهذا يعني أنَّ مُعدّل التضخّم للسنوات الثلاث 4.55 %، وأما إذا أردنا حسابه باستخدام اللوغاريتمات فإنّنا سنحصل على النتيجة نفسها، حيث لدينا:

$$\begin{aligned}\bar{x}_g &= \exp \left[\frac{1}{n} \sum_{i=1}^n \ln x_i \right] = \exp \left[\frac{1}{3} (\ln 3 + \ln 4.5 + \ln 7) \right] \\ &= \exp \left[\frac{1}{3} (1.099 + 1.504 + 1.946) \right] = e^{1.516} = 4.55\end{aligned}$$

٢- إذا كان مُعدّل النمو السكاني لبلد ما هو 3.25 % في سنة 2011، و 2.75 % في سنة 2012 و 2.5 % في سنة 2013 وأخيراً 2.25 % في سنة 2015، فعندئذ يُحسب مُعدّل النمو السكاني للسنوات الأربع من خلال المتوسط الهندسي، ونجد أنَّ:

$$\bar{x}_g = \sqrt[4]{3.25 \times 2.75 \times 2.5 \times 2.25} = 2.66$$

أي إنَّ مُعدّل النمو السكاني للسنوات الأربع يساوي 2.66%.

يقدم لنا التعريف الآتي أحد مقاييس النّزعة المركزيّة الشهيرة أيضاً (ويستخدم عادةً في مسائل التدفق).

(٢, ١, ٥) المتوسط التوافقي Harmonic Mean

لتكن x_1, x_2, \dots, x_n بيانات خام مُعطاة وبحيث يكون $x_i \neq 0$ من أجل كل $i \in N_n$ ، وكذلك $\sum_{i=1}^n x_i^{-1} \neq 0$ ، فعندئذ يُعرّف المتوسط التوافقي لهذه لبيانات من خلال العلاقة الآتية:

$$\bar{x}_h = \frac{1}{\frac{1}{n} \sum_{i=1}^n \frac{1}{x_i}} = n \cdot \left(\sum_{i=1}^n \frac{1}{x_i} \right)^{-1} \quad [2,9-a]$$

$$\mu_h = \frac{1}{\frac{1}{N} \sum_{i=1}^N \frac{1}{x_i}} = N \cdot \left(\sum_{i=1}^N \frac{1}{x_i} \right)^{-1} \quad [2,9-b]$$

علماً أنَّنا استخدمنا الرمز \bar{x}_h من أجل العينات و μ_h من أجل المجتمعات.

(٢, ١, ٥, ١) ملاحظات

١- من العلاقة [2,9-a] نجد أنَّ:

$$\frac{1}{\bar{x}_h} = \frac{1}{n} \sum_{i=1}^n \frac{1}{x_i} \quad [2,10]$$

وهذا يعني أنَّ مقلوب المتوسط التوافقي لمجموعة بيانات يساوي المتوسط لمقلوب البيانات نفسها.

٢- في الحالة الخاصة عندما يكون لدينا $n = 2$ و $n = 3$ و $n = 4$ فإنه يمكننا حساب المتوسط التوافقي \bar{x}_h من خلال العلاقات الآتية على الترتيب:

$$\bar{x}_h = 2 \frac{x_1 \cdot x_2}{x_1 + x_2}$$

$$\bar{x}_h = 3 \frac{x_1 \cdot x_2 \cdot x_3}{x_1 \cdot x_2 + x_1 \cdot x_3 + x_2 \cdot x_3}$$

$$\bar{x}_h = 4 \frac{x_1 \cdot x_2 \cdot x_3 \cdot x_4}{x_1 \cdot x_2 \cdot x_3 + x_1 \cdot x_2 \cdot x_4 + x_1 \cdot x_3 \cdot x_4 + x_2 \cdot x_3 \cdot x_4}$$

وهكذا دواليك.

٣- إنَّ العلاقة التي تربط بين المتوسطات \bar{x} و \bar{x}_g و \bar{x}_h هي:

$$\bar{x}_h \leq \bar{x}_g \leq \bar{x}$$

[2,11]

ومن أجل الحالة الخاصة $n = 2$ يكون لدينا:

$$\bar{x}_h = \frac{(\bar{x}_g)^2}{\bar{x}} \Leftrightarrow \bar{x}_g = \sqrt{\bar{x} \cdot \bar{x}_h}$$

[2,12]

٤- تجدر الإشارة هنا إلى أنَّ المتوسط التوافقي يُستخدم عندما تتعلَّق قيم البيانات ببعض الوحدات، ومن الأمثلة الأكثر شيوعاً على ذلك حساب متوسط السرعة والتدفق، والمثالان الآتيان يوضّحان ذلك.

(٢, ١, ٥, ٢) أمثلة

١- تقطع سيارة مسافرة مسافة مقدارها 10 كم على طريق خارجي بسرعة مقدارها 110 كم/ ساعة، وتتابع على طريق داخلي سريع لتقطع مسافة مقدارها 10 كم بسرعة 65 كم/ ساعة، وأخيراً تسير مسافة مقدارها 10 كم على طريق داخلي في حي شعبي بسرعة 30 كم/ ساعة، فعندئذ يكون متوسط السرعة لهذه السيارة على المسافة المقطوعة (30 كم) هو:

$$\bar{x}_h = 3 / \left(\frac{1}{110} + \frac{1}{65} + \frac{1}{30} \right) = 51.895 \text{ km / h}$$

٢- لدينا ثلاثة صنابير مياه تصبّ ماءً في حوض بحيث إنَّ الصنبور الأول والثاني والثالث يصب في الساعة 700، 900 و1200 لتر في الساعة على الترتيب، ولنحسب متوسط صبّ الصنابير الثلاثة بآن واحد خلال ساعة واحدة.

إنَّ متوسط صبّ الصنابير الثلاثة (مقدَّرة بالليتر في الساعة) بآن واحد يُحسب باستخدام المتوسط التوافقي، فنجد أنَّ:

$$\bar{x}_h = 3 / \left(\frac{1}{700} + \frac{1}{900} + \frac{1}{1200} \right) = 889.412$$

ومنه يكون متوسط صبّ هذه الصنابير يساوي 889.412 لترًا في الساعة.

من الملاحظ أنَّ السمة المشتركة بين \bar{x} و \bar{x}_g و \bar{x}_h هي اعتماد هذه المتوسطات على جميع قيم البيانات، بمعنى أنَّه إذا فقدت إحدى البيانات أو بعضها فإنَّها تصبح غير قابلة للتطبيق، ولهذا كان لا بدَّ من البحث عن مقياس بديل للنزعة المركزية يساعدنا في تجاوز هذه العقبة.

يقدم لنا التعريف الآتي أحد مقاييس النزعة المركزية، وهذا المقياس يُساعدنا في تجاوز مشكلة القيم المتطرفة وفقدان بعض البيانات (ولكن تحت شروط مُحَدَّدة)، أي إنه يقدم لنا حلاً جزئياً لمشكلة فقدان بعض البيانات.

(٦, ١, ٢) الوسيط Median

يُعرف الوسيط (وفي بعض المراجع يذكر باسم "الوسط") لمجموعة من البيانات على أنه القيمة التي يقع على يسارها 50% من البيانات وعلى يمينها 50% من البيانات أيضاً، وذلك بعد ترتيب البيانات تصاعدياً (أو تنازلياً)، علماً أننا سنرمز للوسيط بـ \tilde{x} من أجل العينات وبـ $\tilde{\mu}$ من أجل المجتمعات، ولحسابه سنناقش الحالتين الآتيتين:

١- من أجل البيانات الخام:

نفرض أن x_1, x_2, \dots, x_n بيانات خام مُرتَّبة تصاعدياً (يمكن أن تكون مرتبة تنازلياً أيضاً). عندئذ يُحسب الوسيط لهذه البيانات باستخدام إحدى العلاقتين الآتيتين:

أ- إذا كان حجم البيانات (أو عدد البيانات) n عدداً فردياً، فعندئذ يكون لدينا:

$$\tilde{x} := x_{\frac{n+1}{2}} \quad [2,13-a]$$

ب- إذا كان حجم البيانات (أو عدد البيانات) n عدداً زوجياً، فعندئذ يكون لدينا:

$$\tilde{x} := \frac{x_{\frac{n}{2}} + x_{\frac{n}{2}+1}}{2} \quad [2,13-b]$$

٢- في حالة البيانات المجمعة:

بفرض أنه لدينا بيانات مقدَّمة من خلال جدول التوزيع التكراري (١, ٢)، فعندئذ يُحسب الوسيط لبيانات ذلك الجدول من خلال العلاقة الآتية:

$$\tilde{x} := \tilde{L} + \frac{\frac{\sum f_i}{2} - (\tilde{F} - \tilde{f})}{\tilde{f}} \times C \quad [2,14]$$

علماً أن \tilde{L} هو الحد الأدنى للفئة الفعلية الوسيطة (علماً أن الفئة الوسيطة هي أول فئة تكرارها المتجمُّع الصاعد أكبر أو يساوي نصف مجموع التكرارات)، \tilde{f} هو تكرار الفئة الوسيطة، \tilde{F} هو التكرار المتجمُّع الصاعد للفئة الوسيطة، و C هي سعة الفئة الوسيطة (هنا لم نرفق دليلاً لـ C أو رمزاً خاصاً بها لأننا نتعامل مع فئات متساوية السعة).

أما لو كانت البيانات مقدَّمة من خلال جدول تكراري، فعندئذ نعيد تنظيم الجدول بحيث تصبح قيم الممثلين في الجدول التكراري (١, ٢) مرتَّبة تصاعدياً $x_1 < x_2 < \dots < x_k$. بعد ذلك تُعين قيمة الوسيط كما يلي:

أ- إذا كان مجموع التكرارات $\sum f_i = n$ فردياً فإننا نأخذ الممثل x_i الموافق لأصغر تكرار تراكمي أكبر أو يساوي $\frac{n+1}{2}$.

ب- إذا كان مجموع التكرارات $\sum f_i = n$ زوجياً، وكان لممثل x_i تكرار تراكمي يساوي $\frac{n}{2}$ تماماً، فإن قيمة الوسيط تُحسب

بالعلاقة:

$$\tilde{x} := \frac{x_{\frac{n}{2}} + x_{\frac{n}{2}+1}}{2}$$


وخلاف ذلك نأخذ قيمة أول ممثل للبيانات x_i له تكرار تراكمي أكبر تماماً من $\frac{n}{2}$ كقيمة للوسيط.

(١, ٦, ١, ٢) أمثلة

١- لتكن لدينا البيانات الآتية:

14 8 14 19 5 29 37 14 6 5 19 33 7 42 8 31 25

والآن لتعيين الوسيط لهذه البيانات سنقوم أولاً بترتيبها تصاعدياً، فيصبح لها التوضع الآتي للبيانات:




وبما أن عدد هذه البيانات فردياً فإن قيمة الوسيط تُحسب باستخدام العلاقة [2,13,a] فيكون لدينا:

$$\tilde{x} = x_{\frac{n+1}{2}} = x_{\frac{17+1}{2}} = x_9 = 14$$

٢- لتكن لدينا البيانات الآتية:

15 25 31 8 42 7 33 19 5 6 14 37 29 5 19 14 8 14

فعندئذ لتعيين الوسيط لهذه البيانات يجب ترتيب البيانات المُعطاة تصاعدياً، فيصبح لها التوضع الآتي:



وبما أن عدد هذه البيانات زوجي فإن قيمة الوسيط تُحسب باستخدام العلاقة [2-13-b] فيكون لدينا:

$$\tilde{x} = \frac{x_{\frac{n}{2}} + x_{\frac{n}{2}+1}}{2} = \frac{x_{\frac{18}{2}} + x_{\frac{18}{2}+1}}{2} = \frac{x_9 + x_{10}}{2} = \frac{14 + 15}{2} = 14.5$$

٣- بالرجوع إلى المثال / ٢ / من (١-٢-١-٢) نجد أن قيمة الوسيط لتلك البيانات (بعد ترتيبها تصاعدياً) يحسب باستخدام العلاقة [2-13-b]، ومن ثم يكون لدينا:

$$\tilde{x} = \frac{x_{\frac{n}{2}} + x_{\frac{n}{2}+1}}{2} = \frac{x_{\frac{50}{2}} + x_{\frac{50}{2}+1}}{2} = \frac{x_{25} + x_{26}}{2} = \frac{173 + 174}{2} = 173.5$$

وبعد صيغتها في جدول توزيع تكراري نجد أن الفئة الوسطية لبيانات ذلك الجدول هي الفئة الرابعة (انظر الجدول (٢, ٢))، وأما قيمة الوسيط لبيانات ذلك الجدول فإنها تحسب باستخدام العلاقة [2-14]، ومن ثم يكون لدينا:

$$\tilde{x} := \tilde{L} + \frac{\sum f_i - (\tilde{F} - \tilde{f})}{\tilde{f}} \times C = 170 + \frac{25 - 21}{15} \times 10 = 172.67$$

إنَّ الفارق بين قيمة الوسيط للبيانات الخام وقيمة الوسيط لبيانات جدول التوزيع التكراري الممثل لها يعود للسبب نفسه الذي ذكرناه سابقاً بخصوص المتوسط الحسابي.

٤ - لتكن لدينا مجموعتي بيانات مقدَّمة في الجدول التكراري الآتي (قيم الممثلين قدِّمت مرتبةً تصاعدياً):
الجدول (٣، ٢، *)

رقم الممثل	ممثل البيان	التكرار f_i	التكرار التراكمي للممثل F_i	رقم الممثل	ممثل البيان	التكرار f_i	التكرار التراكمي للممثل F_i
1	$x_1 = 1$	3	3	1	$z_1 = 5$	2	2
2	$x_2 = 3$	5	8	2	$z_2 = 7$	6	8
3	$x_3 = 8$	3	11	3	$z_3 = 11$	7	15
4	$x_4 = 14$	4	15	4	$z_4 = 13$	7	22
5	$x_5 = 15$	4	19	5	$z_5 = 17$	5	27
6	$x_6 = 18$	6	25	6	$z_6 = 25$	3	30
Total	-----	25	-----	Total	-----	30	-----

فنجِد من أجل مجموعة البيانات X أنَّ وسيطها هو $x_4 = 14$ وذلك لأنَّ مجموع التكرارات لها عدد فردي، حيث لدينا $\frac{n+1}{2} = 13$ والممثل x_4 هو أول ممثل بيانات له تكرار تراكمي أكبر أو يساوي 13. أمَّا من أجل مجموعة البيانات Z فنجد أنَّ مجموع التكرارات لها عدد زوجي، وللممثل z_3 تكرار تراكمي يساوي $\frac{n}{2}$ ، ومن ثَمَّ قيمة الوسيط لمجموعة البيانات Z هو:


$$\tilde{x} = \frac{x_3 + x_4}{2} = \frac{11 + 13}{2} = 12$$

(٢، ١، ٦، ٢) ملاحظات

١ - إذا فقدت إحدى أو بعض البيانات المعلوم ترتيبها بين البيانات وغير الواقعة في وسط البيانات المرتبة فإنَّ الوسيط قابل للتطبيق والحساب.

٢ - يُعبَّر عن الوسيط هندسياً على أنَّه القيمة x على محور الفئات التي إذا رسم عندها عمود رأسي فإنَّه سيقسم المدرج التكراري (أو المضلع التكراري) إلى قسمين متساويين (وليس متماثلين بالضرورة).

٣ - يمكن تعيين المنوال هندسياً من خلال إسقاط عمود على محور الفئات من نقطة تقاطع مضلعي التكرار المتجمَّع الصاعد والهابط، فلو عدنا إلى الفقرة (٣، ٥، ١) فإنَّ قيمة الوسيط لبيانات جدول التوزيع التكراري (١٥، ١) موضَّحة في الشكل الآتي.



١- لتكن لدينا البيانات الآتية التي تعرض لنا درجات الحرارة في مدينة X خلال أحد أيام شهر شباط (فبراير) مسجلة كل ساعة بدءاً من الساعة 01:00 صباحاً:

ف نجد أنَّ عدد البيانات زوجياً، وأنَّ الترتيب التصاعدي لهذه البيانات له العرض الآتي:

ومن ثم تكون قيمة الوسيط لهذه البيانات هي:

فلو كانت لدينا بعض البيانات مفقودة (على سبيل المثال، والتي سنشير إليها بـ ؟) المعلوم ترتيبها وغير الواقعة في الوسط، فإننا سنلاحظ أنَّ قيمة الوسط تبقى قابلة للحساب.

٢- بالعودة إلى مثال جمع التبرعات من أحد الفصول الدراسية بمدرسة ما لصالح إحدى الجمعيات الخيرية، وقد لاحظنا سابقاً تأثير قيمة المتوسط الحسابي للتبرعات بالقيمة المتطرفة 100، ولكن لو قمنا بترتيب هذه البيانات تصاعدياً:

ومن ثم نجد أنَّ الوسيط لهذه التبرعات هو:

فوجد أن 50% من المتبرعين لم يتبرعوا بأكثر من 5 ريالات، وهذا يعني أن هذا المقياس للنزعة المركزية المتمثل بالقيمة 5 لم يتأثر بالقيمة المتطرفة 100.

٣- لتكن لدينا البيانات الآتية التي تعرض لنا درجات مجموعة من الطلاب (عدد 47 طالباً) في اختبار منتصف الفصل لمقرر الإحصاء (الدرجة القصوى 20):

13.5	18	8.5	13.5	11.5	8	13	9	17.5	17	14.5	8
13.5	7	11	7.5	6	14	15.5	14	13.5	14.5	16	11.5
8	17.5	18	20	15.5	9.5	1	5.5	13.5	9.5	12.5	7
9.5	15	5	8	11.5	18.5	7	10	8	11.5	7	

وبترتيب هذه البيانات تصاعدياً يصبح لدينا العرض الآتي للبيانات السابقة:

1	5	5.5	6	7	7	7	7.5	8	8	8	8
8.5	9	9.5	9.5	9.5	10	11	11.5	11.5	11.5	12.5	13
13	13.5	13.5	13.5	13.5	14	14	14.5	14.5	14.5	15	15.5
15.5	16	17	17.5	17.5	17.5	17.5	18	18	18.5	20	

وبحساب قيمة الوسيط لهذه البيانات نجد أن:

$$\tilde{x} = x_{\frac{n+1}{2}} = x_{\frac{47+1}{2}} = x_{24} = 13$$

وهكذا نجد أن 50% من الطلاب لهم درجات اختبار أعلى من 13 درجة.

لقد ذكرنا سابقاً أنه من الممكن لمجموعة بيانات أن تنزع إلى أكثر من قيمة، بمعنى أن مجموعة البيانات تتجزأ بحيث كل مجموعة جزئية منها تنزع إلى قيمة مختلفة عن الأخرى، وقد يحصل هذا عادة عندما تكون البيانات متأتية من مصادر مختلفة. إنَّ التعريف الآتي يقدم لنا تعريف هذا النوع من مقاييس النزعة المركزية، حيث سنلاحظ أنَّ هذا المقياس يتميز بسلوك مختلف عن المقاييس السابقة.

(٧, ١, ٢) تعريف (المنوال Mode)

سنرمز للمنوال بـ \hat{x} من أجل العينات وبـ $\hat{\mu}$ من أجل المجتمعات، ولتعريفه سنناقش الحالتين الآتيتين:

١- من أجل البيانات الخام:

بفرض أنَّ x_1, x_2, \dots, x_n بيانات خام مُعطاة (عينة أو لمجتمع الفارق هو استخدام الدليل n أو N فقط)، عندئذ يُعرَّف المنوال على أنه القيمة الأكثر تكراراً بين البيانات.

٢- من أجل البيانات المجمعة:

بفرض أنَّ لدينا بيانات مُعطاة من خلال جدول التوزيع التكراري (١, ٢)، فعندئذ تُحسب قيمة المنوال بوساطة العلاقة الآتية:

$$\hat{x} = \hat{L} + \frac{D_1}{D_1 + D_2} C \quad [2,15]$$

علماً أنَّ: \hat{L} هو الحد الأدنى للفئة المنوالية، D_1 هو الفرق بين تكرار الفئة المنوالية وتكرار الفئة السابقة لها مباشرة، D_2 هو الفرق بين تكرار الفئة المنوالية وتكرار الفئة اللاحقة بها مباشرة، وأخيراً C هو سعة الفئة المنوالية (هنا لم نرفق دليلاً لـ C لأنه لدينا جميع الفئات متساوية السعة). علماً أنَّ الفئة المنوالية هي تلك الفئة التي تكرارها أكبر من تكرار الفئة السابقة لها واللاحقة بها مباشرة، وعلى ألا تكون هذه الفئة طرفية. أي إنَّ الفئة الأولى والأخيرة في التوزيع التكراري لا يُنظر إليهما كفئات منوالية.

أما إذا كانت البيانات مقدّمة من خلال جدول تكراري كما في (١, ٢) (مع مراعاة الملاحظة المرفقة به)، فعندئذ كل قيمة ممثّل للبيانات يقابلها أكبر قيمة تكرار ستكون منوالاً للبيانات (بالطبع إذا كانت جميع قيم التكرارات متساوية فعندئذ ليس للبيانات منوال).

(١, ٧, ١, ٢) أمثلة

١- لتكن لدينا البيانات الآتية:

5 11 8 11 3 11 2 6 7 11 7 9 7 10 15 4 9

ف نجد أنَّ القيمة الأكثر تكراراً هي 11، ومن ثمَّ المنوال لهذه البيانات يساوي 11.

٢- بالرجوع إلى المثال /٢/ من (١, ٢, ١, ٢) نجد أنَّ القيمة الأكثر تكراراً هي 175 (تكرارها يساوي 5)، ومن ثمَّ المنوال لتلك البيانات يساوي 175. أما بعد صبَّ البيانات المُعطاة في جدول توزيع تكراري فنجد أنَّ الفئة المنوالية لبيانات جدول التوزيع التكراري (٢, ٢) هي الفئة الثالثة (انظر الجدول (٢, ٢))، ومن ثمَّ باستخدام العلاقة [2, 15] تكون قيمة المنوال لبيانات ذلك الجدول تساوي:

$$\hat{x} = \hat{L} + \frac{D_1}{D_1 + D_2} C = 160 + \frac{14}{14 + 2} \times 10 = 168.75$$

إنَّ الفارق بين قيمة المنوال للبيانات الخام وبيانات جدول التوزيع التكراري الممثل لها يعود للسبب نفسه الذي ذكرناه سابقاً بخصوص المتوسط الحسابي أيضاً.

٣- بالرجوع إلى المثال /٣/ من (١, ٦, ١, ٢) نجد أنَّ مجموعة البيانات X تملك منوالاً وحيداً هو $x_5 = 15$ ، وأما مجموعة البيانات Z فنجد أنَّها تملك منوالين هما $z_3 = 11$ و $z_4 = 13$ حيث لكلٍ منهما التكرار الأعظمي 7.

(٢, ١, ٧, ٢) ملاحظات

١- إنَّ المنوال قد لا يكون موجوداً، وهذا يوافق الحالة التي تكون فيها جميع البيانات الخام مختلفة بعضها عن بعض، من قبيل:

10 15 3 11 2 6 7 4 9 5 8


أو أنَّ تكون جميع البيانات متساوية، من قبيل:

7 7 7 7 7 7 7 7 7 7 7

أو أنَّ يكون لجميع البيانات التكرار نفسه، من قبيل:

6 4 5 8 0 6 4 6 5 4 8 5 8 0


وأمَّا من أجل التوزيعات التكرارية فإنَّ عدم وجود المنوال يوافق الحالة التي يكون فيها شكل المدرج التكراري (وقبلاً عليه تناقش بقية التمثيلات) للبيانات المجمعة أحد العروض البيانية الآتية:




٢- حتى في حال وجود المنوال، فإنَّه قد لا يكون وحيداً، وهذا يوافق الحالة التي يتساوى فيها التكرار الأعظمي لقيمتين من البيانات على الأقل، فيكون لدينا في هذه الحالة منوالين على الأقل، فعلى سبيل المثال، لو أخذنا البيانات الآتية:

8 11 7 9 7 10 10 3 11 8 6 7 5 8

فلاحظ وجود ثلاثة مناويل لهذه البيانات هي 7، 8 و 11 (حيث لكل منهما ثلاثة تكرارات)، و أما من أجل البيانات المجمعة فيكون لشكل المدرج التكراري (وقياساً عليه تناقش بقية التمثيلات) للبيانات المجمعة قمتين داخليتين على الأقل، والشكل الآتي يوضح ذلك (مدرج تكراري ذو منوالين).



٣- إذا كان المدرج التكراري مُعطى فإنه يمكن تعيين المنوال هندسياً، وذلك من خلال إسقاط عمود على محور الفئات من نقطة تقاطع المستقيمين الواصلين بين النهاية اليمنى لقمة الفئة المنوالية مع النهاية اليمنى لقمة الفئة السابقة لها، وكذلك بين النهاية اليسرى لقمة الفئة المنوالية مع النهاية اليسرى لقمة الفئة اللاحقة بها كما يوضحه الشكل الآتي.



وهذه الطريقة لتعيين المنوال تحتاج إلى دقة في الرسم واستخدام مقاييس دقيقة، ولذلك لا تستخدم إلا عند الضرورة.

(٨, ١, ٢) مقارنة بين صفات المتوسط، والوسيط، والمنوال

١- **المتوسط** هو أكثر مقاييس التزعة المركزية استخداماً في مجال الإحصاء، ويعود ذلك لسهولة حسابه وتعريفه بعلاقة رياضية بسيطة، وكذلك لكونه يأخذ بالحسبان جميع القياسات التي تخضع للدراسة والبحث، كما أنه يخضع للعمليات الجبرية المعروفة، ومن ميزاته أنه إذا عُلِّمت قيمته فإنه يمكن حساب مجموع البيانات إذا كان عددها معلوماً، أو حساب عدد البيانات إذا كان المجموع لها معلوماً، وهذه الخاصية غير متوفرة في الوسيط والمنوال، وإضافة لما سبق فإننا نلاحظ أنه إذا أضفنا إلى البيانات أي عدد من القيم المساوية للمتوسط فإن قيمة هذا المتوسط لا تتغير وذلك لأن المتوسط يُمثل مركز ثقل البيانات أو نقطة اتزان المدرج التكراري، وأخيراً يُفضل استخدامه في الاستنتاج الإحصائي ذلك أن توزيعاته معلومة في الإحصاء (كما سنرى ذلك لاحقاً في الفصل التاسع).

أما أهم عيوب المتوسط الحسابي فهي:

أ- تأثره بالقيم المتطرفة، وللتخلص من هذا العيب يمكن استخدام ما يُعرف باسم المتوسط الحسابي المشدّب Trimmed mean (TrMean) الذي يقوم على ترتيب البيانات أولاً، ومن ثمّ حذف أول 5% وآخر 5% من البيانات (مقرّبة إلى أقرب عدد صحيح)، وبعد ذلك حساب المتوسط لقيم البيانات المتبقية.

ب- يصبح عديم التطبيق في حال سقوط أو فقدان إحدى قيم البيانات أو بعضها.

٢- الوسيط سهل التعريف والحساب، ولا يتأثر بالقيم المتطرفة، ولا يعتمد على جميع القيم دائماً، فتغيّر قيمة من القيم غير الواقعة في الوسط لا يؤثر في قيمة الوسيط، كذلك يستعمل الوسيط في البيانات التي يُعرف ترتيبها ولا تعرف قيمها، وكذلك في البيانات الناقصة كأن تكون إحدى قيم البيانات غير الواقعة في الوسط قد سقطت لسبب ما ولكن معلوم ترتيبها.

أما أهمّ عيوب الوسيط فهي:

أ - انخفاض مستوى دقته مقارنة بالمتوسط لأنّه يعتمد على قيمة واحدة أو اثنتين على الأكثر من قيم البيانات فقط.

ب - عدم إمكانية تطبيقه في حال فقدان بعض البيانات المرتبة الواقعة في الوسط.

٣- المنوال هو أقل هذه المقاييس الثلاثة استخداماً، وفي البيانات القليلة العد يُعدّ غير ذي جدوى عملياً (هذا إن وجد أصلاً)، وأما في حالة البيانات كبيرة العدد، والجداول التكرارية فيمكن الاستفادة منه لكون تأثره بتغيّر بعض قيم البيانات قد لا يكون كبيراً بالقدر الذي يلغي استخدامه، كذلك من فوائده أنّه يمكن استخدامه في حالة البيانات النوعية مثل: معرفة ألوان عيون فئة من الناس، فيُقال إنّ اللون المنوالي هو اللون البنّي، ولكن من عيوبه الكبيرة أنّه قد لا يكون موجوداً، وفي حال وجوده قد لا يكون وحيداً، وهذا يعني أنّه لا يمكن تعريفه بشكل وحيد كمقياس للنزعة المركزية.

(١, ٨, ١, ٢) ملاحظات

١- بالرغم من أنّ المتوسط يُنظر إليه في كثير من الحالات كأفضل مقياس من مقاييس النزعة المركزية، إلّا أنّه يُفضّل استخدامه عندما يكون شكل توزيع البيانات متماثلاً على وجه التقريب، وعندما يكون الاهتمام منصباً على القيمة العددية التي تأخذ جميع القياسات بالحسبان وليس الحصول على قيمة نموذجية مُمثّلة لها فقط، وكذلك عندما تكون جميع البيانات معلومة (أي لا يوجد فيها بيانات مفقودة).

٢- يُفضّل استخدام الوسيط إذا كان اهتمامنا منصباً على إيجاد قيمة مُمثّلة لمركز ثقل البيانات بدلاً من الاهتمام بالمجموع الكلي، وعندما يكون التوزيع ملتوياً، وكذلك عندما تكون لدينا بعض البيانات المفقودة المعلوم ترتيبها وغير الواقعة في وسط البيانات بعد ترتيبها (نصاعدياً أو تنازلياً).

٣- إنّ استخدام المنوال قليل جداً ونادراً ما يُلجأ إليه، ولكن في حال فقدان بعض البيانات الواقعة في وسط البيانات بعد ترتيبها فإنّ للمنوال دور جيد في تعيين مقياس النزعة المركزية للبيانات.

٤ - وجد تجريبياً أنّ المنوال يساوي ثلاثة أمثال الوسيط مطروحاً منه ضعف المتوسط، أي إنّ:

$$\hat{x} = 3\tilde{x} - 2\bar{x} \quad [2,16]$$

(٢, ٢) الربعيات

Quartiles

لقد ناقشنا سابقاً بعضاً من مقاييس الموضع المهمة التي تمثلت بمقاييس النزعة المركزية، ولكن هناك مقاييس موضع أخرى لا تنتمي لمقاييس النزعة المركزية. سنذكر منها نوعين هما الرُّيَعِيَّات والمئينات فقط.


(٢, ٢, ١) تعريف (الرُّيَعِيَّات)

لتكن لدينا x_1, x_2, \dots, x_n مجموعة من البيانات المرتبة تصاعدياً، فعندئذ:

١- القيمة التي يقع قبلها 25% وبعدها 75% من البيانات المرتبة تُدعى **الرُّيَعِيَّ الأول** First Quartile (أو **الرُّيَعِيَّ الأدنى** Lower Quartile)، ويُرمز له بـ Q_1 .

٢- القيمة التي يقع قبلها 50% وبعدها 50% من البيانات المرتبة تُدعى **الرُّيَعِيَّ الثاني** Second Quartile، ويُرمز له بـ Q_2 ، وهنا يُلاحظ أنَّ الرُّيَعِيَّ الثاني هو الوسيط نفسه، أي أنَّ $Q_2 = \tilde{x}$.

٣- القيمة التي يقع قبلها 75% وبعدها 25% من البيانات المرتبة تُدعى **الرُّيَعِيَّ الثالث** Third Quartile (أو **الرُّيَعِيَّ الأعلى** Upper Quartile)، ويُرمز له بـ Q_3 .



هكذا يمكننا تقديم العرض الهيكلي لهذه الرُّيَعِيَّات كما موضح جانباً.

(٢, ٢, ٢) تعيين الرُّيَعِيَّات

في الواقع توجد طرائق عديدة لتعيين الرُّيَعِيَّات، وتتفاوت نتائجها وفقاً لهذه الطريقة أو تلك، وهذا بدوره قد يجعل نتائج حساب الرُّيَعِيَّات تختلف من برنامج إحصائي إلى آخر. في كتابنا هذا سنقدم إحدى هذه الطرائق التي تُعدّ من أكثر الطرائق دقّةً، وهي مستخدمة في بعض البرامج الإحصائية.

لتعيين الرُّيَعِيَّات سنميز بين حالتين:

١- من أجل البيانات الخام:

لتكن x_1, x_2, \dots, x_n بيانات خام مرتبة تصاعدياً (**عَيِّنة أو لمجتمع الفارق هو استخدام الدليل n أو N فقط**)، ولنضع بالتعريف:

$$q_r := \frac{r(n+1)}{4} ; r=1, 2, 3 \quad [2,17]$$

والذي يُدعى **رتبة Rank** الرُّيَعِيَّ r (وهذه القيمة تُحدّد موضع الرُّيَعِيَّ بين البيانات المرتبة)، فعندئذ تُعيّن قيمة الرُّيَعِيَّ Q_r مع $r=1, 2, 3$ على النحو الآتي:

بفرض أنَّ k هو الجزء الصحيح من العدد q_r ، وأنَّ الباقي من هذا العدد يساوي s ، فحينئذ يُحسب الرُّيَعِيَّ Q_r من خلال العلاقة:

$$Q_r = x_k + s(x_{k+1} - x_k) ; r=1, 2, 3 \quad [2,18]$$

لاحظ هنا أنَّه إذا كان الباقي $s=0$ أو كان $x_{k+1} = x_k$ ، فعندئذ سيكون لدينا $Q_r = x_k$.

٢- في حالة البيانات المجمّعة:

بفرض أنَّه لدينا بيانات مُجمّعة في جدول توزيع تكراري كما في الجدول (٢, ١)، ولنضع بالتعريف:

$$q_r := \frac{r \cdot \sum f_i}{4} \quad [2,19]$$

ف عندئذ يُعيّن الرُّيَعِيَّ ذو الرقم r لبيانات هذا الجدول من خلال العلاقة الآتية:

$$Q_r := L_{Q_r} + \frac{q_r - (F_{Q_r} - f_{Q_r})}{f_{Q_r}} \times C \quad ; r = 1, 2, 3 \quad [2,20]$$

علماً أنَّ L_{Q_r} هو الحد الأدنى لفئة الربيعي Q_r ، وأنَّ فئة هذا الربيعي هي أول فئة تكرارها المتجمّع الصاعد أكبر أو يساوي q_r ، f_{Q_r} هو تكرار فئة الربيعي r ، و F_{Q_r} هو التكرار المتجمّع الصاعد لفئة الربيعي r ، وأخيراً C هي سعة الفئة للربيعي r (هنا لم نرفق دليلاً لـ C لأننا نتعامل مع جداول توزيع تكرارية فئاتها متساوية السعة).

في حال كانت البيانات مقدّمة من خلال جدول تكراري، فعندئذ نعيد تنظيم الجدول بحيث تصبح قيم الممثلين في الجدول التكراري (٢، ١) مرتبة تصاعدياً. بعد ذلك نفترض أنَّ البيانات الأصل هي y_1, y_2, \dots, y_n مع $n = \sum f_i$ و $y_1 < y_2 < \dots < y_n$ ، ومن ثمَّ نحسب رتبة الربيعي r بوساطة العلاقة [2,17] لهذه البيانات، فإن كانت قيمة q_r عدداً صحيحاً ووجدت قيمة ممثّل x_i في الجدول التكراري لها تكرار تراكمي يساوي q_r فإننا نأخذ تلك القيمة كقيمة للربيعي r ، وخلاف ذلك نأخذ أول قيمة لمثّل x_i في الجدول التكراري لها تكرار تراكمي أكبر من q_r كقيمة للربيعي r . أما إذا كانت قيمة q_r عدداً غير صحيح، فعندئذ نطبّق على البيانات المرتبة y_1, y_2, \dots, y_n العلاقة الآتية:

$$Q_r = y_\ell + s(y_{\ell+1} - y_\ell) \quad ; r = 1, 2, 3$$

علماً أنَّ ℓ هنا هو الجزء الصحيح من q_r و y_ℓ هي أول قيمة ممثّل x_i في الجدول التكراري لها تكرار تراكمي أكبر أو يساوي ℓ ، و $y_{\ell+1}$ هي القيمة x_i نفسها إذا كان $F_i > \ell$ ، وخلاف ذلك (أي أنَّ $F_i = \ell$) تكون $y_{\ell+1}$ هي x_{i+1} من الجدول التكراري.

(١، ٢، ٢، ٢) أمثلة

١- تمّ معايرة المادة الفعّالة لعينة عشوائية بحجم $n = 20$ كبسولة سُحبت من إنتاج مصنع لكبسولات مضاد حيوي عيار 500 mg، فكانت لدينا البيانات الآتية بعد ترتيبها تصاعدياً:

480	482	483	485	490	492	495	495	500	500
505	510	510	515	525	525	535	537	549	550

ولنقم بتعيين الربيعيات الثلاثة Q_1 ، Q_2 و Q_3 ونقدّم تفسيراً لها.

العمل: إنَّ رتبة الربيعي الأول، والثاني، والثالث على الترتيب هي:

$$q_1 = \frac{n+1}{4} = \frac{20+1}{4} = 5.25 \quad \& \quad q_2 = \frac{2(n+1)}{4} = \frac{20+1}{2} = 10.5 \quad \& \quad q_3 = \frac{3(n+1)}{4} = \frac{3(20+1)}{4} = 15.75$$

ومن ثمَّ تكون قيم الربيعيات الثلاثة Q_1 ، Q_2 و Q_3 على الترتيب هي:

$$Q_1 = x_5 + 0.25(x_6 - x_5) = 490 + 0.25(492 - 490) = 490.5$$

$$Q_2 = x_{10} + 0.5(x_{11} - x_{10}) = 500 + 0.5(505 - 500) = 502.5$$

$$Q_3 = x_{15} + 0.75(x_{16} - x_{15}) = 525 + 0.75(525 - 525) = 525$$

وهذا يعني أنَّ وفقاً لمعطيات العينة لدينا 25% من المنتج يحوي على كمية أقل من 490.5 mg، ونصف المنتج يحوي على كمية أقل من 502.5 mg، وأخيراً 25% من المنتج يحوي على كمية أكثر من 525 mg.

٢- لتكن لدينا بيانات مجمّعة في جدول التوزيع التكراري الآتي، والتي تمثّل نتائج الاختبار النهائي لـ 48 طالباً في مقرّر الإحصاء:

الجدول (٤, ٢)

رقم الفئة	الحدود الفعلية للفئة	مركز الفئة x_i	تكرار الفئة f_i	التكرار المتجمّع الصاعد للفئة F_i	رقم الفئة
1	25 → 30	27.5	5	5	1
2	30 → 35	32.5	9	14	2
3	35 → 40	37.5	16	30	3
4	40 → 45	42.5	8	38	4
5	45 → 50	47.5	5	43	5
6	50 → 55	52.5	3	46	6
Total	-----	---	48	-----	Total

ولنقم بتعيين الرُّيَعِيَّات الثلاثة Q_1 ، Q_2 و Q_3 ونقدّم تفسيراً لها.

العمل: إنّ رتبة الرُّيَعِيَّ الأول، والثاني، والثالث على الترتيب هي:

$$q_1 = \frac{48}{4} = 12 \quad \& \quad q_2 = \frac{2 \times 48}{4} = 24 \quad \& \quad q_3 = \frac{3 \times 48}{4} = 36$$

ومن ثمّ تكون قيمة الرُّيَعِيَّ الأول، والثاني، والثالث على الترتيب هي:

$$Q_1 = L_{Q_1} + \frac{q_1 - (F_{Q_1} - f_{Q_1})}{f_{Q_1}} \times C = 30 + \frac{12 - (14 - 9)}{9} \times 5 = 33.89$$

$$Q_2 = L_{Q_2} + \frac{q_2 - (F_{Q_2} - f_{Q_2})}{f_{Q_2}} \times C = 35 + \frac{24 - (30 - 16)}{16} \times 5 = 38.125$$

$$Q_3 = L_{Q_3} + \frac{q_3 - (F_{Q_3} - f_{Q_3})}{f_{Q_3}} \times C = 40 + \frac{36 - (38 - 8)}{8} \times 5 = 43.75$$

ومن ثمّ وفقاً لمعطيات هذه العينة فإنّ 75% من الطلاب الذين تقدّموا إلى الاختبار حصلوا على درجات أعلى من 33.89 درجة، وأنّ نصفهم حصلوا على درجات فوق 39 درجة (ومثلهم دون 39 درجة)، وأخيراً فإنّ 75% منهم حصلوا على درجات أقل من 44.125 درجة.

٣- بالرجوع إلى المثال /٣/ من (١, ٦, ١, ٢). لنقم بتعيين الرُّيَعِيَّات الثلاثة Q_1 ، Q_2 و Q_3 لمجموعة البيانات X .

ولنقم بتعيين الرُّيَعِيَّات الثلاثة Q_1 ، Q_2 و Q_3 ، فنجد أنّ:

$$q_1 = \frac{26}{4} = 6.5 \quad \& \quad q_2 = \frac{54}{4} = 13.5 \quad \& \quad q_3 = \frac{78}{4} = 19.5$$

ومن ثمّ نجد أنّ جميع قيم q_r هي أعداد غير صحيحة، وبالتالي يكون لدينا:

- من أجل Q_1 لدينا الجزء الصحيح من q_r هو $\ell = 6$ ومن ثمّ تكون قيمة $y_\ell = x_2 = 3$ ، وبما أنّ $F_2 = 8 > \ell = 6$ فإنّ

$y_{\ell+1} = x_2 = 3$ أيضاً، وبالتالي يكون لدينا:

$$Q_1 = y_6 + 0.5(y_7 - y_6) = x_2 + 0.5(x_2 - x_2) = x_2 = 3$$

- من أجل Q_2 لدينا الجزء الصحيح من q_r هو $\ell = 13$ ومن ثم تكون قيمة $y_\ell = x_4 = 14$ ، وبما أن $F_4 = 15 > \ell = 13$ فإن $y_{\ell+1} = x_4 = 14$ أيضاً، وبالتالي يكون لدينا:

$$Q_1 = y_{13} + 0.5(y_{14} - y_{13}) = x_4 + 0.5(x_4 - x_4) = x_4 = 14$$

- من أجل Q_3 لدينا الجزء الصحيح من q_r هو $\ell = 19$ ، ومن ثم تكون قيمة $y_\ell = x_5 = 15$ ، وبما أن $F_5 = \ell = 19$ فإن $y_{\ell+1} = x_6 = 18$ ، وبالتالي يكون لدينا:

$$Q_3 = y_{19} + 0.5(y_{20} - y_{19}) = x_5 + 0.5(x_6 - x_5) = 15 + 0.5(18 - 15) = 16.5$$

(٢, ٢, ٢, ٢) ملاحظات

- ١- تجدر الإشارة هنا إلى أنه من الممكن أن تكون قيمة الرُّبَيعي موجودة بين القيم المرتبة المُعطاة.
- ٢- لقد لاحظنا أن القيمة Q_2 هي الوسيط، ومن ثم Q_2 هو مقياس للنزعة المركزية. في حين أن القيمتين Q_1 و Q_3 ليستا من مقاييس النزعة المركزية، ولكنهما مقاييس موضع فقط.
- ٣- من استخدامات الرُّبَيعيات تحديد إن كانت قيمة x من مجموعة بيانات مُعطاة هي قيمة متطرفة (Extreme Value) (أو قيمة منعدلة Outlier Value) أم لا. حيث يُقال عن قيمة x من مجموعة بيانات مُعطاة إنها قيمة متطرفة إذا حققت إحدى العلاقتين (*) و (**) الآتيتين:

$$x < Q_1 - 1.5(Q_3 - Q_1) \quad (*)$$

وفي هذه الحالة نقول إن القيمة x متطرفة بصغرها، وأما القيمة $Q_1 - 1.5(Q_3 - Q_1)$ فإنها تُدعى Lowest Fence وسنرمز لها بـ LF أي إنه لدينا:

$$LF \triangleq Q_1 - 1.5(Q_3 - Q_1)$$

وهي تمثل في الواقع الحد الأعلى للقيم المتطرفة بصغرها لدى مجموعة بيانات مُعطاة.

$$x > Q_3 + 1.5(Q_3 - Q_1) \quad (**)$$

وفي هذه الحالة نقول إن القيمة x متطرفة بكبرها، وأما القيمة $Q_3 + 1.5(Q_3 - Q_1)$ فإنها تُدعى Highest Fence وسنرمز لها بـ HF أي إنه لدينا:

$$HF \triangleq Q_3 + 1.5(Q_3 - Q_1)$$

وهي تمثل في الواقع الحد الأدنى للقيم المتطرفة بكبرها لدى مجموعة بيانات مُعطاة.

فعلى سبيل المثال لو أخذنا البيانات الآتية:

6	7	7	4	15	5	5	4	5	3	4	5	7	3	4
1	4	5	4	4	7	5	5	6	5	7	1	6	4	7

ف نجد أن $Q_1 = 4$ و $Q_3 = 6.25$ ، ومن ثم ينتج لدينا $Q_3 - Q_1 = 6.25 - 4 = 2.25$ ، وبالتالي يكون:

$$HF = Q_3 + 1.5(Q_3 - Q_1) = 6.25 + (1.5)(2.25) = 9.625 < 15$$

$$LF = Q_1 - 1.5(Q_3 - Q_1) = 4 - (1.5)(2.25) = 0.625 < 1$$

ف نجد أن القيمة 15 متطرفة بكبرها ولا وجود لقيمة متطرفة بصغرها.

(٢,٣) المئينات

Percentiles

النوع الآخر من مقاييس الموضع هو ما يُعرف باسم "المئينات". في الواقع إنَّ المئين يوفّر معلومات حول كيفية امتداد البيانات من أصغر قيمة إلى أكبر قيمة، فعلى سبيل المثال يُذكر في كثير من الأحيان في جدول نتائج اختبار القبول للكليات والجامعات من حيث النسب المئوية، فيقال على سبيل المثال إنَّ 65% فقط من المتقدمين استوفوا الشروط المطلوبة للتعين. أو إنَّ 85% فقط من الطلاب حقّقوا درجة النجاح في المقرّر. لكن التعريف الرياضي لهذا المفهوم تقدّمه الفقرة الآتية.

(٢,٣,١) تعريف (المئيني الرائي r -Percentile):

المئينات هي تسع وتسعون قيمة عددية تقسم البيانات بعد ترتيبها تصاعدياً إلى مئة شريحة (أو جزء) متساوية الأعداد من القيم، بحيث يكون في كل شريحة العدد نفسه من قيم البيانات. فلو كانت لدينا x_1, x_2, \dots, x_n مجموعة من البيانات (العينة أو المجتمع الفارق هو استخدام الدليل n أو N فقط) المرتبة تصاعدياً، فعندئذ القيمة التي يقع قبلها $r\%$ من البيانات (من البيانات المرتبة) وبعدها $(100 - r)\%$ تُدعى المئيني الرائي r -Percentile (أو المئيني ذو الرقم r)، وسنرمز له بـ P_r .

من تعريف المئينات نلاحظ أنَّ $P_{25} = Q_1$ ، $P_{50} = Q_2 = \tilde{x}$ ، وكذلك $P_{75} = Q_3$. كذلك يُلاحظ بسبب العدد الكبير للمئينات أنَّ هذا النوع من المقاييس يكون أكثر وضوحاً كلما ازداد عدد البيانات، ولذلك تكون نتائج هذا النوع من المقاييس أكثر دقة عندما يكون عدد البيانات كبيراً.

(٢,٣,٢) تعيين المئينات

توجد طرائق عديدة لتعيين المئينات، وتتفاوت نتائجها وفقاً لهذه الطريقة أو تلك. في كتابنا هذا سنقدّم إحدى الطرائق المستخدمة في البرامج الإحصائية التي تعدّ من أكثر الطرائق دقة.

لتعيين المئينات سنميز بين حالتين:

١- من أجل البيانات الخام:

لتكن x_1, x_2, \dots, x_n بيانات خام مرتبة تصاعدياً (العينة أو مجتمع، والفارق هو استخدام الدليل n أو N فقط)، ولنضع بالتعريف:

$$p_r := \frac{r(n+1)}{100} ; r \in \mathbb{N}_{99} \quad [2,21]$$

الذي يُدعى رتبة المئين P_r في البيانات المرتبة (وهو يحدّد موضع المئين بين البيانات المرتبة). عندئذ لتعيين قيمة المئين P_r من أجل أي $r \in \mathbb{N}_{99}$ نقوم بما يلي:

بفرض أنَّ k هو الجزء الصحيح من المقدار p_r ، وأنَّ الباقي منه يساوي s ، فعندئذ تُحسب قيمة المئين P_r من خلال العلاقة الآتية:

$$P_r = x_k + s(x_{k+1} - x_k) ; r \in \mathbb{N}_{99} \quad [2,22]$$

نلاحظ هنا أنَّه إذا كان $s = 0$ أو $x_{k+1} = x_k$ فإنَّه سيكون لدينا $P_r = x_k$ فقط.

٢- في حالة البيانات المجمعة:

بفرض أنَّه لدينا بيانات مُجمّعة في جدول توزيع تكراري كما في الجدول (٢,١) ولنضع بالتعريف:

$$p_r := \frac{r \cdot \sum f_i}{100} ; r \in \mathbb{N}_{99} \quad [2,23]$$

عندئذ يُعيّن المئين ذا الرقم r لبيانات هذا الجدول من خلال العلاقة الآتية:

$$P_r := L_{P_r} + \frac{p_r - (F_{P_r} - f_{P_r})}{f_{P_r}} \times C \quad ; r \in N_{99} \quad [2,24]$$

علماً أنّ L_{P_r} هو الحد الأدنى لفئة المئين P_r ، وأنّ الفئة الخاصة بالمئين P_r هي أول فئة تكرارها المتجمّع الصاعد أكبر أو يساوي p_r ، f_{P_r} هو تكرار الفئة الخاصة بالمئين P_r ، و F_{P_r} هو التكرار المتجمّع الصاعد للفئة الخاصة بالمئين P_r ، وأخيراً C هي سعة الفئة الخاصة بالمئين P_r (هنا لم نرفق دليلاً لـ C لأن جميع الفئات متساوية السعة).

في حال كانت البيانات مقدّمة من خلال جدول تكراري، فعندئذ نعيد تنظيم الجدول بحيث تصبح قيم الممثلين في الجدول التكراري $(2, 1)$ مرتّبة تصاعدياً، وبعد ذلك نفترض أنّ البيانات الأصل هي y_1, y_2, \dots, y_n مع $n = \sum f_i$ و $y_n > \dots > y_2 > y_1$ ، ومن ثمّ تُحسب رتبة المئين r بوساطة العلاقة [2,21] لهذه البيانات، فإن كانت قيمة p_r عدداً صحيحاً ووجدت قيمة ممثّل x_i في الجدول التكراري لها تكرارها تراكمي يساوي p_r فإننا نأخذ تلك القيمة كقيمة للمئين r ، وخلاف ذلك نأخذ أول قيمة لممثّل x_i في الجدول التكراري لها تكرارها تراكمي أكبر من p_r كقيمة للمئين r . أما إذا كانت قيمة p_r عدداً غير صحيح، فعندئذ نطبّق على البيانات المرتّبة y_1, y_2, \dots, y_n العلاقة الآتية:

$$Q_r = y_\ell + s(y_{\ell+1} - y_\ell) \quad ; r \in N_{99}$$

علماً أنّ ℓ هنا هو الجزء الصحيح من p_r و y_ℓ هي أول قيمة ممثّل x_i في الجدول التكراري لها تكرارها تراكمي أكبر أو يساوي ℓ ، و $y_{\ell+1}$ هي القيمة x_i نفسها إذا كان $F_i > \ell$ ، وخلاف ذلك (أي أنّ $F_i = \ell$) تكون $y_{\ell+1}$ هي x_{i+1} من الجدول التكراري.

(١, ٢, ٣, ٢) أمثلة

١- بالعودة إلى المثال / ١ / من (١, ٢, ٣, ٢) وبعد ترتيب تلك البيانات تصاعدياً يصبح لها العرض الآتي:

147	160	168	171	172	173	177	180	189
149	160	168	171	172	173	178	181	190
149	160	169	171	172	173	178	181	190
152	163	169	171	172	173	178	181	192
147	160	168	170	172	173	177	180	189
152	163	169	171	173	173	178	182	192
154	163	169	171	173	175	178	182	193
155	163	169	171	173	175	178	183	193
157	163	169	171	173	175	179	183	193
157	165	169	172	173	175	179	184	195
158	167	169	172	173	175	179	185	195
158	167	169	172	173	175	179	185	196
158	167	170	172	173	175	179	188	
160	167	170	172	173	175	179	188	
160	168	170	172	173	175	180	189	

بيانات المثال / ١ / من (١, ٢, ٣, ٢) بعد ترتيب تصاعدياً

ولنقم بتعيين المئين P_{35} و P_{89} لهذه البيانات.

نعلم أنَّ عدد البيانات $n = 132$ ، ومن ثمَّ تكون رتبة المئين P_{35} و P_{89} على الترتيب هي:

$$p_{35} = \frac{35(n+1)}{100} = \frac{35(132+1)}{100} = 46.90 \quad \& \quad p_{89} = \frac{89(n+1)}{100} = \frac{89(132+1)}{100} = 119.26$$

ومن ثمَّ يكون لدينا:

$$P_{35} = x_{46} + 0.90(x_{47} - x_{46}) = 170 + 0.90(171 - 170) = 170.90$$

$$P_{89} = x_{119} + 0.26(x_{120} - x_{119}) = 189 + 0.40(189 - 189) = 189$$

٢- لنعد إلى بيانات المثال / ١ / من (١-٢-٢-٢) حيث لدينا $n = 20$ ، ولنقم بحساب المئينين P_{15} و P_{85} .

العمل: من أجل ذلك نجد رتبة المئين P_{15} و P_{85} على الترتيب هي:

$$p_{15} = \frac{15(n+1)}{100} = \frac{15(20+1)}{100} = 3.15 \quad \& \quad p_{85} = \frac{85(n+1)}{100} = \frac{85(20+1)}{100} = 17.85$$

ومن ثمَّ يكون لدينا:

$$P_{15} = x_3 + 0.15(x_4 - x_3) = 483 + 0.15(485 - 483) = 483 + 0.30 = 483.30$$

$$P_{85} = x_{17} + 0.85(x_{18} - x_{17}) = 535 + 0.85(537 - 535) = 535 + 1.7 = 536.7$$

٣- بالعودة إلى بيانات المثال / ٢ / من (١, ٢, ٢, ٢)، ولنقم بتعيين قيم المئينات P_{25} و P_{50} و P_{75} لبيانات ذلك الجدول.

من أجل ذلك نلاحظ أنَّ رتب هذه المئينات على الترتيب هي:

$$p_{25} = \frac{25 \sum_{i=1}^k f_i}{100} = \frac{25 \times 48}{100} = 12 \quad \& \quad p_{50} = \frac{50 \sum_{i=1}^k f_i}{100} = 24 \quad \& \quad p_{75} = \frac{75 \sum_{i=1}^k f_i}{100} = 36$$

وأنَّ الفئة الخاصَّة بالمئين P_{25} هي الفئة الثانية لأنَّها أول فئة تكرارها المتجمُّع الصَّاعد أكبر أو يساوي p_{25} ، ومن ثمَّ يكون لدينا:

$$P_{25} = L_{P_{25}} + \frac{p_{25} - (F_{P_{25}} - f_{P_{25}})}{f_{P_{25}}} \times C = 30 + \frac{12 - (14 - 19)}{9} \times 5 = 33.89$$

وكذلك الفئة الخاصَّة بالمئين P_{50} هي الفئة الثالثة لأنَّها أول فئة تكرارها المتجمُّع الصَّاعد أكبر أو يساوي p_{50} ، ومن ثمَّ يكون لدينا:

$$P_{50} = L_{P_{50}} + \frac{p_{50} - (F_{P_{50}} - f_{P_{50}})}{f_{P_{50}}} \times C = 35 + \frac{24 - (14 - 19)}{9} \times 5 = 45.56$$

وأخيراً الفئة الخاصَّة بالمئين P_{75} هي الفئة الرابعة لأنَّها أول فئة تكرارها المتجمُّع الصَّاعد أكبر أو يساوي p_{75} ، ومن ثمَّ يكون لدينا:

$$P_{75} = L_{P_{75}} + \frac{p_{75} - (F_{P_{75}} - f_{P_{75}})}{f_{P_{75}}} \times C = 40 + \frac{36 - (14 - 19)}{9} \times 5 = 57.22$$

لاحظ أنَّ هذه المئينات التي تمَّ حسابها هي الرُّبعيات الثلاثة Q_1 و Q_2 و Q_3 .

٣- بالرجوع إلى المثال /٣/ من (١, ٦, ١, ٢). لنقم بتعيين المئين الثلاثة P_{35} لمجموعة البيانات Z ، فنجد أن رتبة المئين P_{35} هي:

$$P_{35} = \frac{35(n+1)}{100} = \frac{35(30+1)}{100} = 10.85$$

ومن ثم الجزء الصحيح من P_{35} هو $\ell = 10$ ، ومنه تكون قيمة $y_\ell = z_3 = 11$ ، وبما أن $F_3 = 15 > \ell = 10$ فإن $y_{\ell+1} = z_3 = 11$ أيضاً، وبالتالي يكون لدينا:

$$Q_1 = y_{10} + 0.85(y_{11} - y_{10}) = z_3 + 0.85(z_3 - z_3) = z_3 = 11$$

(٢, ٣, ٢, ٢) ملاحظات

١- نشير هنا إلى أن المئينات تستخدم عادة عندما يكون حجم البيانات كبيراً بقدر كاف (وغالباً أكثر من 99 قيمة)، وأن ما قُدم سابقاً وسيقدم لاحقاً من أمثلة على بيانات قليلة العدد كان من باب التوضيح والتبسيط فقط.

٢- توجد أكثر من طريقة لتعيين المئين الموافق لآية قيمة من قيم بيانات خام مُعطاة، ومنها الطريقتين الآتيتين:

طريقة أولى: لتكن x_1, x_2, \dots, x_n بيانات خام مُرتبة تصاعدياً (عيّنة أو لمجتمع الفارق هو استخدام الرمز n أو N فقط)، ومن أجل $1 \leq i \leq n$ لرمز ب P_{x_i} لقيمة المئين الموافقة للقيمة x_i ، فعندئذ من أجل أية قيمة $N_n \ni i$ تُعطى قيمة P_{x_i} بوساطة العلاقة الآتية:

$$P_{x_i} := \frac{i}{n+1} \times 100 \% \quad (\text{نقرأ كنسبة مئوية}) \quad [2,25-a]$$

طريقة ثانية: هذه الطريقة أقل دقة من الطريقة السابقة ولكنها مقبولة لتعيين المئين الموافق لآية قيمة من قيم بيانات خام x_1, x_2, \dots, x_n بيانات خام مُرتبة تصاعدياً، عندئذ تُعطى قيمة P_{x_i} من أجل أية قيمة $N_n \ni i$ بوساطة العلاقة الآتية:

$$P_{x_i} := \frac{N_i + 0.5}{n} \times 100 \% \quad (\text{نقرأ كنسبة مئوية}) \quad [2,25-b]$$

علماً أن N_i هو عدد البيانات المرتبة التي أصغر من القيمة x_i .

(٢, ٣, ٢, ٣) أمثلة:

١- لتكن لدينا البيانات الآتية:

2 9 6 3 2 -1 0

ولنستخدم العلاقة [2,25-a] لتعيين المئينات للبيانات المُعطاة.

بعد ترتيب هذه البيانات تصاعدياً نجد المئين الموافق لكل قيمة من القيم المرتبة كما في الجدول الآتي (قمنا باستخدام الجدول على سبيل التوضيح والإيجاز فقط):

الجدول (٥, ٢)

x_i	-1	0	2	2	3	6	9	قيمة ما x أكبر تماماً من x_7
	x_1	x_2	x_3	x_4	x_5	x_6	x_7	$< x$
P_{x_i}	12.5	25	36.5	50	62.5	75	87.5	100

نلاحظ هنا أنه لو طلب منا حساب المئين P_{88} للبيانات المُعطاة فإنه لن نستطيع تعيينه لأن أكبر قيمة في البيانات مئها 87.5.

٢- لتكن لدينا البيانات الآتية:

5 3 1 7 6 6 11 25 9 12

باستخدام العلاقة [2,25-a] لتعيين المئينات للبيانات المُعطاة نجدها كما في الجدول الآتي:

الجدول (٢, ٦)

x_i	1	3	5	6	6	7	9	11	12	25	$< x$
x_1	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_{10}	
P_{x_i}	9.09	18.18	27.27	36.36	45.45	54.55	63.64	72.73	81.82	90.91	100

نلاحظ هنا أنه كلما زاد عدد البيانات فإنه يمكننا حساب مئينات من مراتب أعلى، وعلاوة على ذلك يُلاحظ أن القيمة المئينية لأية قيمة مُرتبة x_i هي من مضاعفات القيمة المئينية لأصغر قيمة في البيانات x_1 ، وأنه لدى أية قيمة x تالية لأكبر قيمة في البيانات سيكون لدينا $P_{x_i} = 100\%$ ليشير بذلك على أن جميع البيانات تقع قبل هذه القيمة x .

٣- لتكن لدينا البيانات الآتية:

9 -3 5 -2 9 7 6 4 4 6 3

ولنستخدم العلاقة [2,25-b] لتعيين المئينات للبيانات المُعطاة. بالطبع بعد ترتيب هذه البيانات تصاعدياً فإن المئين الموافق لكل قيمة من هذه القيم المرتبة نجدها تساوي القيمة المقابلة لها في الجدول الآتي:

الجدول (٢, ٧)

x_i	-3	-2	3	4	4	5	6	6	7	9	9
x_1	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_{10}	x_{11}
N_i	0	1	2	3	4	5	6	7	8	9	10
P_{x_i}	4.5	13.6	22.7	31.8	40.9	50	59.1	68.2	77.3	86.4	95.5

فلو أردنا على سبيل المثال تعيين المئين P_{50} للبيانات المُعطاة، فإننا نجد ما يلي:

$$p_{50} = \frac{50(n+1)}{100} = \frac{50(11+1)}{100} = 6.00 \Rightarrow P_{50} = x_6 = 5$$

ف نجد أنها تتوافق مع نتيجة الطريقة التي نستخدم العلاقة [2,25-b]، حيث كان للقيمة $x_6 = 5$ المئين $P_{x_6} = 50$ ، أي إن $P_{x_6} = P_{50}$ ، ولكن كما ذكرنا سابقاً فإن هذه الطريقة ليست دقيقة، فمن الممكن أن تكون قيمة P_{x_i} أكبر أو أصغر من القيمة الحقيقية للمئين، فعلى سبيل المثال نجد من أجل P_{25} و P_{75} ما يلي:

$$p_{25} = \frac{25(n+1)}{100} = \frac{25(11+1)}{100} = 3.00 \Rightarrow P_{25} = x_3 = 3 \Rightarrow P_{x_3} < P_{25}$$

$$p_{75} = \frac{75(n+1)}{100} = \frac{75(11+1)}{100} = 9.00 \Rightarrow P_{75} = x_9 = 7 \Rightarrow P_{x_9} > P_{75}$$

(٢, ٤) مقاييس التشتت


Dispersion Measures

لقد قدمنا في الفقرة السابقة عرضاً لأهم مقاييس النزعة المركزية وأخرى للموضع، وكان لكل منها ميزاته التي تجعل منه مقياساً مفضلاً من أجل حالات مُحَدَّدة، ولكن هذه المقاييس للنزعة المركزية لا تقدِّم وصفاً دقيقاً لتوزيع البيانات، ذلك أنَّه من المهم معرفة كيفية توزُّع هذه البيانات حول القيمة الممثلة لمقياس نزعتها المركزية (متوسطها، وسيطها أو منوالها) أيضاً، حيث يسأل المرء إن كانت البيانات قريبة من هذه القيمة أم أنَّها متناثرة بشكل متباعد عنها، فعلى سبيل المثال لو أخذنا مجموعتي البيانات الآتية حيث تمثِّل كل منهما درجات الحرارة في مدينة مأخوذة كل ساعتين خلال يوم كامل:

الجدول (٨، ٢)

الوقت	6	8	10	12	14	16	18
المدينة X	8	9	18	35	33	24	18
المدينة Y	17	18	20	25	24	21	20

فنجِد أنَّ متوسط درجات الحرارة في كلا المدينتين خلال هذا اليوم يساوي 20.71 إلا أنَّ تبعثر قيم درجات الحرارة حول متوسطها يختلف من مدينة لأخرى، حيث نلاحظ أنَّ قيم درجات الحرارة في المدينة X لها توضعَات مختلفة تماماً عما هو عليه الحال لدى قيم درجات الحرارة في المدينة Y (انظر الشكل الآتي).



الشكل (٦، ٢).

إذن لا بدَّ من وجود مقاييس تُوضِّح لنا كيفية تبعثر (أو تشتَّت) البيانات حول مقياس نزعتها المركزية لكي يتكوَّن لدينا انطباع أكثر وضوحاً حول سلوك البيانات.

سنقدِّم فيما يلي أهم مقاييس التشتُّت (أو مقاييس التبعثر **Scatter Measures** أو مقاييس الانتشار **Spread Measures**) التي تُندرج تحت مُسمَّى **مقاييس الاختلاف** Variability Measures.

في الواقع لو حظَّ أنَّه يمكن النظر للفروقات بين قيم البيانات عن متوسطها كمقياس للتشتُّت، ولكن نعلم أنَّ المجموع الجبري لهذه الفروق يساوي الصفر دوماً، لذلك من الممكن أخذ القيم المطلقة للفروق بين البيانات ومتوسطها من أجل استخدامها كمقياس للتشتُّت، وعلى هذا الأساس بُني تعريف **الانحراف المتوسط** Mean Deviation (أو **معدَّل الانحرافات** **Average Deviations**) حيث يُستخدم في حسابه كل قيم البيانات. في الواقع يقوم الانحراف المتوسط على أخذ المتوسط للمسافات بين كل قيمة والمتوسط لهذه البيانات، ومن ثمَّ يُطينا قراراً معقولاً ومقبولاً حول كيفية تبعثر البيانات حول متوسطها.

(١، ٤، ٢) الانحراف المتوسط Mean Deviation

من أجل تعريف **الانحراف المتوسط** لمجموعة بيانات (وَيُرمز له بـ MD)، سنناقش الحالتين الآتيتين:
أولاً: من أجل البيانات الخام:

أ- إذا كانت x_1, x_2, \dots, x_n بيانات عينة بمتوسط \bar{x} ، فعندئذ يُعرَّف الانحراف المتوسط لهذه البيانات بوساطة العلاقة الآتية:

$$MD := \frac{1}{n} \sum_{i=1}^n |x_i - \bar{x}| \quad [2,26-a]$$

ب- إذا كانت x_1, x_2, \dots, x_n بيانات مجتمع بمتوسط μ ، فعندئذ يُعرَّف الانحراف المتوسط لهذه البيانات بوساطة العلاقة الآتية:

$$MD := \frac{1}{N} \sum_{i=1}^N |x_i - \mu| \quad [2,26-b]$$

كما ذكرنا سابقاً فإنَّ الانحراف المتوسط لمجموعة بيانات هو المتوسط الحسابي للمسافات الفاصلة بين قيم البيانات ومتوسطها.

ثانياً: من أجل البيانات المُجمَّعة:

بفرض أنَّه لدينا بيانات مُجمَّعة في جدول توزيع تكراري كما في الجدول (١، ٢)، فعندئذ:

أ- إذا كانت هذه البيانات لعينة متوسطها \bar{x} ، فعندئذ يُعرَّف الانحراف المتوسط لهذه البيانات من خلال العلاقة الآتية:

$$MD := \frac{1}{\sum_{i=1}^k f_i} \sum_{i=1}^k f_i \cdot |x_i - \bar{x}| \quad [2,27-a]$$

ب- إذا كانت هذه البيانات لمجتمع متوسطه μ ، فعندئذ يُعرَّف الانحراف المتوسط لهذه البيانات من خلال العلاقة الآتية:

$$MD := \frac{1}{\sum_{i=1}^k f_i} \sum_{i=1}^k f_i \cdot |x_i - \mu| \quad [2-27-b]$$

(١، ١، ٤، ٢) أمثلة

١- لتكن لدينا البيانات الآتية التي تُمثِّل الأجر الساعية لعينتين من العمال في مهنتين مختلفتين (مُقدَّرة بوحدة نقدية ما):

الجدول (٩، ٢)

العامل	A	B	C	D	E	F	G	H
الأجر الساعي للمهنة X	3	8	5	10	7	15	7	9
الأجر الساعي للمهنة Y	7	8	5	8	17	6	8	5

ف نجد أنَّ قيم المتوسط لمجموعتي البيانات X و Y هما $\bar{x} = 8$ و $\bar{y} = 8$ ، وأما الانحراف المتوسط لكل منهما فإنه يساوي:

$$MD_X = \frac{1}{8} \sum_{i=1}^8 |x_i - \bar{x}| = 2.50 \quad \& \quad MD_Y = \frac{1}{8} \sum_{i=1}^8 |y_i - \bar{y}| = 2.25$$

وهكذا يُظهر لنا هذا المقياس أنَّ تشتت البيانات X حول متوسطها أكبر من تشتت البيانات Y حول متوسطها.

٢- بالرجوع إلى جدول التوزيع التكراري (٢، ٢) في المثال /٢/ من (١، ٢، ١، ٢) نجد أنَّ قيمة الانحراف المتوسط لتلك

البيانات يساوي:

$$MD = \frac{1}{\sum_{i=1}^8 f_i} \sum_{i=1}^8 f_i |x_i - \bar{x}| = \frac{461.2}{50} = 9.224$$

(٢، ١، ٤، ٢) ملاحظة

من الممكن حساب الانحراف المتوسط حول الوسيط (وسنرمز له بـ \tilde{MD}) أو حول المنوال (في حال وجوده ووحده، وسنرمز له بـ

\hat{MD}) وذلك على النحو الآتي (حيث تُستخدم هذه المقاييس في ضبط الجودة الإحصائي وبعض الدراسات الاجتماعية).

أولاً: من أجل البيانات الخام:

$$\mathbf{MD} := \frac{1}{n} \sum_{i=1}^n |x_i - \tilde{x}| \quad \text{for a sample with median } \tilde{x}$$

$$\mathbf{MD} := \frac{1}{n} \sum_{i=1}^n |x_i - \tilde{\mu}| \quad \text{for a population with median } \tilde{\mu}$$

$$\mathbf{MD} := \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}| \quad \text{for a sample with mode } \hat{x}$$

$$\mathbf{MD} := \frac{1}{n} \sum_{i=1}^n |x_i - \hat{\mu}| \quad \text{for a population with mode } \hat{\mu}$$

ثانياً: من أجل البيانات المجمعة:

$$\mathbf{MD} := \frac{1}{\sum_{i=1}^k f_i} \sum_{i=1}^k f_i \cdot |x_i - \tilde{x}| \quad \text{for a sample with median } \tilde{x}$$

$$\mathbf{MD} := \frac{1}{\sum_{i=1}^k f_i} \sum_{i=1}^k f_i \cdot |x_i - \tilde{\mu}| \quad \text{for a population with median } \tilde{\mu}$$

$$\mathbf{MD} := \frac{1}{\sum_{i=1}^k f_i} \sum_{i=1}^k f_i \cdot |x_i - \hat{x}| \quad \text{for a sample with mode } \hat{x}$$

$$\mathbf{MD} := \frac{1}{\sum_{i=1}^k f_i} \sum_{i=1}^k f_i \cdot |x_i - \hat{\mu}| \quad \text{for a population with mode } \hat{\mu}$$

(٣, ١, ٤, ٢) مثال

لتكن لدينا البيانات الآتية التي تمثل عدد الأخطاء المرتكبة من قبل لاعبي كرة القدم لأحد الأندية في مباريات للدوري العام.

الجدول (١٠, ٢)

اللعبة	1	2	3	4	5	6	7	8	9	10
عدد الأخطاء	7	5	7	6	2	9	4	5	7	3

ف نجد أن $\bar{x} = 5.5$ و $\tilde{x} = 5.5$ و $\hat{x} = 7$ ، ومن يكون لدينا:

$$\mathbf{MD} = \frac{1}{n} \sum_{i=1}^n |x_i - \bar{x}| = \frac{1}{10} \sum_{i=1}^{10} |x_i - \bar{x}| = \frac{19}{10} = 1.9$$

$$\mathbf{MD} = \frac{1}{n} \sum_{i=1}^n |x_i - \tilde{x}| = \frac{1}{10} \sum_{i=1}^{10} |x_i - \tilde{x}| = \frac{19}{10} = 1.9$$

$$\mathbf{MD} = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}| = \frac{1}{10} \sum_{i=1}^{10} |x_i - \hat{x}| = \frac{17}{10} = 1.7$$

إذا قمنا بمقارنة هذه النتائج مع ما حصلنا عليه حول المتوسط نجد أن $\mathbf{MD} = \mathbf{MD} \neq \mathbf{MD}$.

لقد لاحظنا فيما سبق أن المتوسط الحسابي للقيم المطلقة لفروقات قيم البيانات عن متوسطها يعطي مقياساً مقبولاً لمدى تبعثر البيانات حول متوسطها، ولكن وجد أن هذا المقياس يصبح أفضل إذا أخذ الجذر التربيعي الموجب للمتوسط الحسابي لمربعات الفروق بين البيانات ومتوسطها. إنَّ التعريف الآتي يمهد لهذا المقياس.

(٢, ٤, ٢) تعريف (التباين Variance)

من أجل تعريف التباين لبيانات مُعطاة سنميز بين الحالتين الآتيتين:

أولاً: من أجل البيانات الخام:

أ) إذا كانت البيانات x_1, x_2, \dots, x_n لعينة متوسطةها \bar{x} ، فعندئذ يُعرّف التباين لهذه البيانات (ويُرمز له بـ S^2) من خلال العلاقة الآتية:

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \quad [2,28-a]$$

ب) إذا كانت هذه البيانات هي x_1, x_2, \dots, x_N لمجتمع إحصائي متوسطه μ ، فعندئذ يُعرّف التباين لهذه البيانات (ويُرمز له بـ σ^2) من خلال العلاقة الآتية:

$$\sigma^2 := \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2 \quad [2,28-b]$$

ثانياً: من أجل البيانات المجمعة:

بفرض أنه لدينا بيانات مُجمعة في جدول توزيع تكراري كما في الجدول (١, ٢)، فإذا كانت هذه البيانات:

أ- هي بيانات لعينة حجمها $n = \sum_{i=1}^k f_i$ ومتوسطها \bar{x} ، فعندئذ يُعرّف التباين (ويُرمز له بـ S^2 أيضاً) لهذه البيانات من خلال العلاقة الآتية:

$$S^2 = \frac{1}{n-1} \sum_{i=1}^k f_i (x_i - \bar{x})^2 \quad [2,29-a]$$

ب- هي بيانات مجتمع حجمه $N = \sum_{i=1}^k f_i$ ومتوسطه μ ، فعندئذ يُعرّف التباين (ويُرمز له بـ σ^2 أيضاً) لهذه البيانات من خلال العلاقة الآتية:

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^k f_i (x_i - \mu)^2 \quad [2,29-b]$$

(١, ٢, ٤, ٢) ملاحظات

١- إن استخدام رمز التربيع فوق الرمز S أو σ للدلالة على أن التباين هو مقدار غير سالب، وأن القيمة الناتجة عنه تقرأ بالوحدة المربعة لوحة القياس المستخدمة في البيانات، فعلى سبيل المثال إذا كانت وحدة القياس للبيانات هي المتر فإن قيمة التباين لهذه البيانات تُقرأ بالمتر المربع، ولهذا السبب فإن قيمة التباين لا تستخدم بشكل مباشر كمقياس للتشتت.

٢- إن الصيغة العامة لتباين مجموعة من القيم العشوائية والمتساوية النصيب في الاختيار x_1, x_2, \dots, x_n وذات متوسط \bar{x} هي (بشكلها الرياضي - وفقاً لنظرية الاحتمالات):

$$\tilde{S}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \quad [2,30]$$

التي تمثل التباين لمتغير عشوائي خاضع للتوزيع المنتظم المتقطع بوسيط n (انظر الفصلين السادس والسابع)، ولهذا فإن صيغة التباين للمجتمع الإحصائي (الذي يمثلها σ^2) توافق الصيغة العامة للتباين. أما إذا كانت هذه البيانات هي بيانات عينة بحجم n ، فإن صيغة التباين تُكتب بأحد الشكلين الآتين:

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \quad \text{for raw data}$$

$$S^2 = \frac{1}{n-1} \sum_{i=1}^k f_i (x_i - \bar{x})^2 \quad \text{for grouped data}$$

وكلا هاتين العلاقتين تُعرف باسم **التباين العملي** (أو **تباين العينة**) Empirical Variance للبيانات، وتبرير استخدامه من أجل العينات تجده في الفصل العاشر. لكن عندما يكون حجم العينة n كبيراً (أي إن $n \geq 32$)، فإنه يُنظر إلى الفارق بين التباين والتباين العملي على أنه مقدار صغير يمكن إهماله، وإذا كان حجم العينة صغيراً (أي إن $n < 32$)، فإنه يُفضل استخدام صيغة التباين العملي. أما من أجل البيانات المجمعة في جداول فإنه غالباً ما يكون عددها كبيراً، ومن ثم استخدام صيغة التباين العملي ستعطي قيمة قريبة جداً من القيمة الناتجة عن الصيغة العامة للتباين، ولذلك استخدام أي الصيغتين سيكون مقبولاً، ولكن في حال كان مجموع التكرارات صغيراً فإنه يجب استخدام صيغة التباين العملي.

٣- إن مجموع مربعات الانحرافات لبيانات x_1, x_2, \dots, x_n عن أي عدد حقيقي a يكون أصغرياً عندما يكون $a = \bar{x}$. إذ إنه باستخدام مفهوم النهايات الحدية (راجع مفهوم النهايات الحدية في حساب التفاضل) يكون لدينا:

$$\left(\sum_{i=1}^n (x_i - a)^2 \right)' = 2 \sum_{i=1}^n (x_i - a) = 2 \sum_{i=1}^n x_i - 2na = 0$$

والتي ينتج عنها أن $2na = 2 \sum_{i=1}^n x_i$ ، ومن ثم يكون لدينا $a = \frac{1}{n} \sum_{i=1}^n x_i$ ، ولهذا السبب يُنظر إلى مفهوم التباين على أنه أفضل مقياس للتشتت.

٤- إن الجذر التربيعي الموجب للتباين يُعرف باسم **الانحراف المعياري** Standard Deviation، وهو يستخدم وحدة قياس البيانات نفسها، ويُرمز له بـ S إذا كانت البيانات لعينة، وأما إذا كانت البيانات لمجتمع فإنه يُرمز له بـ σ ، أي إنه لدينا:

$$\sigma := +\sqrt{\sigma^2} \quad \text{for a population} \quad [2,31-a]$$

$$S := +\sqrt{S^2} \quad \text{for a sample} \quad [2,31-b]$$

ويُعرف الجذر التربيعي الموجب لتباين العينة (العلاقة [2,31-b]) باسم **الانحراف المعياري العملي** Empirical Standard Deviation (أو **الانحراف المعياري للعينة**).

٥- إن تباين مجموعة من البيانات يمكن أن يُحسب من خلال العلاقة الآتية أيضاً وهي تستخدم قيم البيانات بشكل مباشر دون اللجوء إلى حساب المتوسط أو معرفة قيمته:

$$\sigma^2 = \frac{1}{N^2} \left[N \sum_{i=1}^N x_i^2 - \left(\sum_{i=1}^N x_i \right)^2 \right] \quad \text{for population} \quad [2,32,a]$$

$$S^2 = \frac{1}{n(n-1)} \left[n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2 \right] \quad \text{for sample} \quad [2,32,b]$$

(٢, ٢, ٤, ٢) أمثلة

١- لتكن لدينا البيانات الآتية التي تمثل تكلفة إصلاح 60 جهاز حاسب (مقدرة بالدولار) في معامل جامعة ما:

52	99	92	86	84	52	99	92	86	84	63	72	76	95	88	63
72	76	95	88	92	58	65	79	80	92	58	65	79	80	90	75
74	56	99	90	75	74	56	99	65	79	80	90	75	74	56	99
90	75	74	56	74	56	99	65	79	80	90	75				

ف نجد أنَّ متوسط التكلفة لإصلاح الحاسب \bar{x} يساوي:

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} = \frac{52+99+92+.....+90+75}{60} = \frac{4681}{60} = 78.02$$

فلو افترضنا أنَّ الأجهزة المعطلة في الجامعة تمثِّل مجتمعاً إحصائياً، فعندئذ نجد أنَّ التباين لتكلفة الإصلاح هو:

$$\sigma^2 = \frac{1}{N^2} \left[N \sum_{i=1}^N x_i^2 - \left(\sum_{i=1}^N x_i \right)^2 \right] = \frac{1}{60^2} [60 (376247) - (4681)^2] = 184.18$$

لاحظ هنا أنَّنا لا نذكر الوحدة المستخدمة من أجل البيانات لأنَّه ليس لها معنى، ففي حالتنا هذا ما معنى أن نقول إنَّ تباين تكلفة إصلاح الأجهزة يساوي 184.18 دولاراً مربعاً، ولذلك نلجأ إلى حساب قيمة الانحراف المعياري حيث نجد أنَّ قيمة الانحراف المعياري لتكلفة الإصلاح تساوي:

$$\sigma = +\sqrt{\sigma^2} = +\sqrt{184.18} = 13.57 \text{ \$}$$

وأما إذا نظرنا إلى الأجهزة المعطلة في الجامعة على أنَّها عينة من مجتمع الأجهزة المعطلة، فعندئذ نجد أنَّ التباين لتكلفة الإصلاح هو:

$$S^2 = \frac{1}{n(n-1)} \left[n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2 \right] = \frac{1}{60 \times 59} [60 (376247) - (4681)^2] = 187.305$$

ومن ثمَّ تكون قيمة الانحراف المعياري لتكلفة الإصلاح تساوي:

$$S = +\sqrt{S^2} = +\sqrt{187.305} = 13.69 \text{ \$}$$

٢- بالعودة إلى بيانات المثال / ١ / من (١، ٤، ٢، ٩) المُعطاة من خلال الجدول (٩، ٢) سنقوم بحساب الانحراف المعياري للأجر الساعي لعمال كل من المهنتين.

لدينا متوسط الأجر الساعي للعمال في كل المهنتين يساوي 8 دولارات، وحجم العينة في كل منهما يساوي 8 أشخاص، وبما أنَّ عدد البيانات صغير، فعندئذ:

أ- من أجل البيانات X يُحسب تباينها من خلال العلاقة:

$$S_X^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{7} \sum_{i=1}^8 (x_i - \bar{x})^2 = \frac{90}{7} = 12.86$$

ومن ثمَّ تكون قيمة الانحراف المعياري للأجر الساعي لعمال المهنة X تساوي:

$$S_X = +\sqrt{S_X^2} = +\sqrt{12.86} = 3.59 \text{ \$}$$

ب- وأما من أجل البيانات Y فيُحسب تباينها من خلال العلاقة:

$$S_Y^2 = \frac{1}{m-1} \sum_{i=1}^m (y_i - \bar{y})^2 = \frac{1}{7} \sum_{i=1}^8 (y_i - \bar{y})^2 = \frac{104}{7} = 14.86$$

ومن ثم تكون قيمة الانحراف المعياري للأجر الساعي لعمال المهنة Y تساوي:

$$S_Y = +\sqrt{S_Y^2} = +\sqrt{14.86} = 3.85 \text{ \$}$$

هكذا نلاحظ أن هذا المقياس أوضح لنا أن تشتت البيانات X حول متوسطها أقل من تشتت البيانات Y حول متوسطها. فإذا رجعنا إلى قيم الانحراف المتوسط لهذه البيانات حيث لدينا $MD_X = 2.50$ و $MD_Y = 2.25$ فإننا نلاحظ أن مقياس الانحراف المعياري أظهر لنا نتيجة مناقضة لمقياس الانحراف المتوسط. ولهذا نأخذ بنتيجة الانحراف المعياري للبيانات لأنها الأكثر دقة. بالطبع هذه المصادفة في النتائج ليست قاعدة عامة فمن الممكن أن تتفق نتائج المقاييس مع بعضها.

٣- بالرجوع إلى المثال / ٢ / من (١, ٢, ١, ٢) (قياسات الضغط الانقباضي للقلب) حيث لدينا بيانات عينة مقدمة من خلال جدول التوزيع التكراري (٢, ٢)، فنجد أن التباين لبيانات ذلك الجدول تساوي:

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n f_i (x_i - \bar{x})^2 = \frac{6602.5}{49} = 134.745$$

ومن ثم تكون قيمة الانحراف المعياري للضغط الانقباضي الخاص بالعينة التي تم فحص مرضاها تساوي:

$$S = +\sqrt{S^2} = +\sqrt{134.745} = 11.61 \text{ mmHg}$$

(٢, ٤, ٣) قاعدة تشبشيف التجريبية Chebyshev's Empirical Rule

لقد اكتشف عالم الرياضيات الروسي (السوفييتي سابقاً) تشبشيف (Pafnuty Lvovich Chebyshev (1821–1894 أن عدد القياسات التي تقع بين قيمتين متناظرتين حول المتوسط يرتبط بقيمة الانحراف المعياري لهذه القياسات. إن قاعدة تشبشيف التجريبية التي سنقدمها بعد قليل (والتي يمكن استنتاجها من متباينة تشبشيف في نظرية الاحتمالات - انظر المبرهنة (١, ٥, ٢, ٧) في الفصل السابع-) تُعطينا تقديراً متحفظاً (لأنها لا تعطي التقدير من أجل كل القيم) لعدد القياسات الواقعة ضمن انحراف قدره $\pm k \cdot S$ عن المتوسط \bar{x} ، وبذلك يمكننا تقدير عدد القياسات التي يُفترض أن تنتمي إلى الفترة $[\bar{x} - k S, \bar{x} + k S]$. نشير إلى أن هذه القاعدة تكون أقرب إلى الدقة كلما كان شكل توزيع البيانات أقرب إلى التناظر (أو التماثل).

(١, ٢, ٤, ٣) نص القاعدة التجريبية لـ تشبشيف

لتكن لدينا مجموعة بيانات مُعطاة، و $1 < k$ عدداً حقيقياً مُعطى، فعندئذ إذا كانت هذه البيانات:

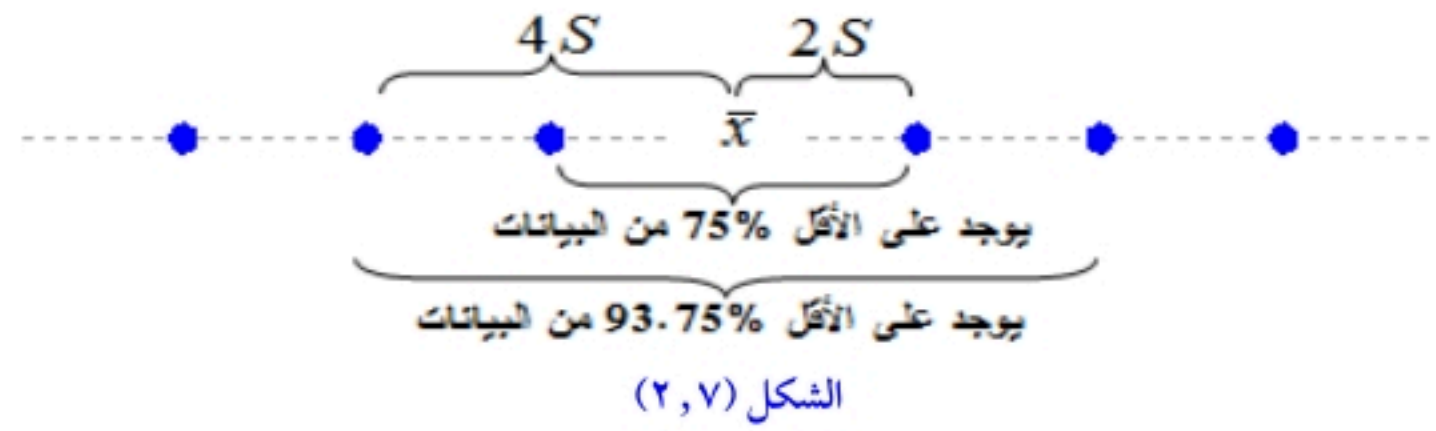
أ- هي x_1, x_2, \dots, x_n لعينة متوسطها \bar{x} وانحرافها المعياري S ، فإنه يوجد على الأقل $\left(1 - \frac{1}{k^2}\right) \times 100\%$ من البيانات ضمن الفترة $[\bar{x} - k S, \bar{x} + k S]$ ، ومن ثم يقع $\frac{100}{k^2}\%$ من البيانات خارج هذه الفترة.

ب- هي x_1, x_2, \dots, x_N لمجتمع متوسطه μ وانحرافه المعياري σ ، فإنه يوجد على الأقل $\left(1 - \frac{1}{k^2}\right) \times 100\%$ من البيانات ضمن الفترة $[\mu - k \sigma, \mu + k \sigma]$ ، ومن ثم يقع $\frac{100}{k^2}\%$ من البيانات خارج هذه الفترة.

الجدول الآتي والرسم الذي يليه يوضحان لنا ما سبق من أجل بعض القيم المختلفة لـ $k < 1$ (حيث يُلاحظ عدم جدوى هذه القاعدة عندما يكون $k = 1$).

الجدول (١١، ٢)

k	2	3	4	5	6	7	8	9	10
$\frac{1}{k^2} \times 100$	25	11.11	6.25	4	2.78	2.04	1.56	1.23	1
$(1 - \frac{1}{k^2}) \times 100$	75	88.88	93.75	96	97.96	97.96	98.44	98.77	99



(٢، ٤، ٣، ٢) مثال

بالرجوع إلى بيانات المثال ١ / من (٢، ١، ٢، ١) (مجتمع أطوال طلاب في مدرسة ثانوية). حيث وجدنا متوسط القيم للبيانات المعطاة $\mu = 172.82$ ، وبحساب قيمة الانحراف المعياري لتلك البيانات نجدها (على افتراض أنها بيانات مجتمع إحصائي) $\sigma = 10.32$ ، ومن ثم يفترض أن يكون لدينا:

١- لا يقل عن 75% من البيانات تقع ضمن الفترة $[\mu - 2\sigma, \mu + 2\sigma]$ التي هي:


$$[152.18, 193.46] = [172.82 - 20.64, 172.82 + 20.64]$$

فلو قمنا بعدّ البيانات الواقعة ضمن هذه الفترة لوجدنا عددها يساوي 123 قيمة، ونسبتها إلى الكل (وهو يساوي 132) يساوي 93.18% وهذا متوافق تماماً مع هذه القاعدة.

٢- لا يقل عن 93.75% من البيانات تقع ضمن الفترة: $[\mu - 4\sigma, \mu + 4\sigma]$ التي هي:

$$[131.54, 214.10] = [172.82 - 41.28, 172.82 + 41.28]$$

وبعدّ البيانات الواقعة ضمن هذه الفترة فإننا نجدها تساوي 132 قيمة (جميع البيانات) ونسبتها إلى الكل يساوي 100% وهذا متوافق تماماً مع هذه القاعدة أيضاً، وسبب هذا التوافق الممتاز في النتائج يعود إلى توزيع البيانات التي لدينا، فلو قمنا بعرض المدرج التكراري لتلك البيانات الذي له العرض الآتي:




الشكل (٢, ٨)

فلاحظ أن لهذا الشكل تناظراً مقبولاً (قريب من التوزيع الطبيعي).

Range المدى (٢, ٤, ٤)

الآن بالعودة إلى مقاييس التشتت، فإذا صادفنا في بعض الحالات فقداناً لبعض البيانات، فعندئذ لا يمكننا استخدام مقياسي التشتت السابقين (الانحراف المتوسط والانحراف المعياري) لأنهما يعتمدان في حسابهما على جميع قيم البيانات، ومن هنا جاءت أهمية البحث في تقديم مقاييس أخرى للتشتت لا تعتمد على جميع قيم البيانات. من المقاييس التي يمكن أن تفيدنا في هذا المضمار **المدى (الذي قدمنا تعريفه سابقاً لدى تشكيل جدول التوزيع التكراري)** وذلك عندما تكون أكبر وأصغر قيمة في البيانات ليست في عداد البيانات المفقودة. إن هذا المفهوم (المدى) هو من المقاييس المستخدمة للدلالة على تشتت البيانات أيضاً، ولكن لا يُنظر إليه كمقياس جيد للتشتت رغم أنه يعطي صورة عن مدى تشتت مجموعة من البيانات، إذ إنه وفي كثير من الحالات (وخاصة لدى العينات الكبيرة الحجم) لا يُظهر لنا بجلاء توضع البيانات حول متوسطها لأنه يأخذ الفرق بين أكبر وأصغر قيمة فقط، وحتى من أجل بعض العينات الصغيرة فقد لا يكون منصفاً في قياس التشتت بين البيانات حول متوسطها، فعلى سبيل المثال لو عدنا إلى المثال / ١ / من (١, ٤, ٢) حيث لدينا مجموعتي بيانات مُعطاة بالجدول (٩, ٢)، فلو قمنا بحساب المدى للأجر الساعي لعمال كل من المهنتين لوجدنا $R_X = 15 - 3 = 12$ وكذلك $R_Y = 17 - 5 = 12$ أيضاً (انظر الشكل الآتي لانتشار البيانات حول المتوسط لكل من مجموعتي البيانات X و Y).



الشكل (٢, ٩)

علماً أن قيم المتوسط لمجموعة البيانات X و Y هي على الترتيب $\bar{x} = 8$ و $\bar{y} = 8$ وهما متساويتان أيضاً، ولكن نلاحظ تفاوتاً واضحاً في تشتت البيانات حول متوسطها لكل من هاتين المجموعتين.

(١, ٤, ٢) مزايا وعيوب المدى كمقياس للتشتت:

بالرغم من أن المدى يُعدّ مقياساً ضعيفاً للتشتت إلا أنه يتمتع بمجموعة من المزايا تجعل منه مقياساً مرغوباً في بعض الحالات، فمن مزايا المدى:

- ١- إنه بسيط وسهل الحساب.
- ٢- يكثر استخدامه عند الإعلان عن حالات الطقس، والمناخ الجوي، مثل درجات الحرارة، والرطوبة، والضغط الجوي.
- ٣- له استخدامات مهمة في بعض الدراسات الإحصائية مثل ضبط الجودة الإحصائي.

(٢, ٤, ٢) عيوب المدى كمقياس للتشتت:

- ١- يعتمد على قيمتين فقط، ولا يأخذ جميع القيم في الحسبان، ومن ثم تكون قيمته أقل دقة من المقاييس السابقة.
- ٢- يتأثر بالقيم المتطرفة بشكل كبير جداً لأنه يعتمد على القيم التي تقع على الأطراف أصلاً.
- ٣- يصبح عديم الاستخدام إذا فُقدت أصغر أو أكبر قيمة في البيانات (هنا "أو" لا تفيد الحصر).

إذاً والحال كذلك، فلا بدّ من البحث عن مقياس آخر يتجاوز السلبيات للمقياس السابق. إنّ مقياس التشتت الآتي يقدم لنا حلاً لمشكلة وجود قيم متطرفة في البيانات.

(٢, ٤, ٥) تعريف (المدى الربيعي Interquartile Range)

لتكن لدينا بيانات مُعطاة، فعندئذ يُعرّف **المدى الربيعي** (ويُرمز له **IQR**) من خلال العلاقة الآتية:

$$IQR = Q_3 - Q_1 \quad [2,33]$$

علماً أنّ Q_1 و Q_3 هما الربيعي الأول والثالث للبيانات على الترتيب.

لاحظ أنّ هذا المقياس يحسب المدى لنصف عدد البيانات الواقعة في الوسط بعد ترتيبها تصاعدياً، ومن ثمّ فإنّ القيم المتطرفة ستصبح خارج نطاق هذا المقياس. من جهة أخرى يُعدّ هذا المقياس (**المدى الربيعي**) أفضل من سابقه (**المدى**) إلّا أنّه يعتمد في قراره على قيمتين من البيانات فقط ولا يأخذ في الحسبان مواضع جميع البيانات، ولهذا السبب يُنظر إلى هذا المقياس على أنّه مقياس ضعيف للتشتت أيضاً، ولكنه يُعدّ مقبولاً في حال فقدان بعض البيانات المعلوم ترتيبها وغير الموافقة لقيمتي الربيعين الأول والثالث.

فلو عدنا إلى المثال ١ / من (١, ١, ٤, ٢)، فإننا نجد ما يلي:

$$Q_{1,X} = 5.50, \quad Q_{1,Y} = 5.25, \quad Q_{3,X} = 9.75 \text{ and } Q_{3,Y} = 8$$

وهكذا يكون لدينا المدى الربيعي لمجموعة البيانات X هو:

$$IQR_X = Q_{3,X} - Q_{1,X} = 9.75 - 5.50 = 4.25$$

في حين نجد أنّ المدى الربيعي لمجموعة البيانات Y هو:

$$IQR_Y = Q_{3,Y} - Q_{1,Y} = 8 - 5.25 = 2.75$$

أي إنّ لمجموعة البيانات X تشتت مختلف عن تشتت مجموعة البيانات Y ، وهكذا نجد أنّه ما عجز عنه المدى (في إظهار فروق التشتت لمجموعتي البيانات) أنجزه المدى الربيعي، حيث بيّن وجود فارق بين تشتت البيانات لكلّ من هاتين المجموعتين.

الآن، وقبل الانتقال للفقرة التالية نشير إلى أنّ نصف قيمة المدى الربيعي (وسنرمز لها بـ Q) تُدعى **الانحراف الربيعي** Quartile Deviation، وتُستخدم كمقياس للتشتت أيضاً. أي إنّ:

$$Q := \frac{Q_3 - Q_1}{2} \quad [2,34]$$

لقد لاحظنا أنّ مقاييس التشتت تعتمد على وحدة القياس المستخدمة من أجل البيانات، ومن ثمّ يكون من الصعب علينا (إن لم يكن متعباً) إجراء المقارنة بين التشتت لمجموعتين أو أكثر من البيانات عندما تكون وحدات القياس المستخدمة من أجل كلّ منها مختلفة عن الأخرى، لذلك كان لابدّ من وضع معيار يمكننا من إجراء المقارنة بين تشتت البيانات حول متوسطها لمجموعتين أو أكثر من البيانات حتى في حال كانت وحدات القياس مختلفة بعضها عن بعض. إنّ المعيار الآتي والمُسمّى **معامل التغير** يُحقّق لنا ذلك، إذ أنّه يستخدم نسبة الانحراف المعياري إلى المتوسط الحسابي لإلغاء خاصية وحدة القياس المستعملة وإظهار مفعول التباين بأن واحد، ومن ثمّ تقديم هذه القيمة كنسبة مئوية خاصة بالبيانات.

(٢, ٤, ٦) تعريف (معامل التغير Coefficient of Variation)

إنَّ مُعامل التَّغْيَر يُقدِّم لنا قيمة تجعلنا نشعر بمدى التَّغْيَر الحاصل لمُتَغْيَر ما، وهو يُمثِّل نسبة الانحراف المعياري إلى المتوسط، ويفيدنا في مقارنة إحصائية لدرجة التباين من مجموعة بيانات إلى أخرى حتى ولو كانت وحدات القياس تختلف بشكل كبير بعضها عن بعض، وذلك لأنَّ قيمة هذا المُعامل هي عدد مجرَّد، ومن أجل تعريفه سنميِّز بين حالتين:

أ- إذا كانت البيانات المُعطاة لعينة بمتوسط $\bar{x} \neq 0$ وانحراف معياري S ، فعندئذ يُعرَّف مُعامل التَّغْيَر (الذي يُرمز له بـ CV) لهذه البيانات من خلال العلاقة الآتية:

$$CV := \frac{S}{\bar{x}} \times 100 \% \quad [2,35-a]$$

ب- إذا كانت البيانات المُعطاة لمجتمع بمتوسط $\mu \neq 0$ وانحراف معياري σ ، فعندئذ يُعرَّف مُعامل التَّغْيَر (الذي يُرمز له بـ CV أيضاً) لهذه البيانات من خلال العلاقة الآتية:

$$CV := \frac{\sigma}{\mu} \times 100 \% \quad [2,35-b]$$

وفي كلا الحالتين يُقرأ الناتج كنسبة مئوية (كما هو واضح في العلاقتين السابقتين).

(١, ٢, ٤, ٦) مثال

لتكن لدينا مجموعتي بيانات تمثِّل الطول والوزن لستة أشخاص (ذكور) بالغين، ومُقدَّمتين من خلال الجدول الآتي:

الجدول (١٢, ٢)

الشخص	A	B	C	D	E	F
X الطول بـ سم	182	173	168	177	169	189
Y الوزن بـ كغ	85	72	68	73	71	93

حيث نلاحظ اختلاف وحدة القياس بين هاتين المجموعتين.

الآن، وبحساب قيم المتوسط والانحراف المعياري لكل من هاتين المجموعتين نجد أنَّ:

$$\bar{x} = 176.33 \text{ cm} \quad \& \quad S_X = 8.09 \text{ cm} \quad \& \quad \bar{y} = 77 \text{ Kg} \quad \& \quad S_Y = 9.78 \text{ Kg}$$

ومنه تكون قيمة مُعامل التَّغْيَر لمجموعة البيانات X هي $CV_X = 4.59 \%$ ، في حين نجد قيمة مُعامل التَّغْيَر لمجموعة البيانات Y هي $CV_Y = 12.70 \%$ ، ومن ثَمَّ تكون قيمة مُعامل تَغْيَر الطول أصغر بكثير من مُعامل تَغْيَر الوزن لهذه العينة من الأشخاص.

(٢, ٤, ٦, ٢) ملاحظات

١- تُعرَّف القيمة المطلقة لمُعامل الاختلاف باسم **الانحراف المعياري النسبي** (Relative Standard Deviation (RSD)، ويُعبَّر عنها كنسبة مئوية أيضاً.

٢- في حال تَعَدُّر حساب المتوسط أو التباين فإنه يمكن أن يُستعاض عن مُعامل التَّغْيَر بمُعامل آخر يُدعى مُعامل التشتت، وهو يُحسب بدلالة الرُّبعيين الأول والثالث، ويقدمه لنا التعريف الآتي.

(٢, ٤, ٧) تعريف (مُعامل التشتت Coefficient of Dispersion)

لتكن لدينا مجموعة بيانات مُعطاة لها رُّبعي أول Q_1 ورُّبعي ثالث Q_3 ، فعندئذ يُعرَّف مُعامل التشتت (الذي يُرمز له بـ CD) من خلال العلاقة الآتية:

$$CD := \frac{Q_3 - Q_1}{Q_3 + Q_1} \times 100 \% \quad [2,36]$$

(١, ٢, ٤, ٧) مثال

لتكن لدينا مجموعة بيانات خام مُرتّبة، ولكنها تحوي بيانات مفقودة معلوم ترتيبها ومُعطاة كما في العرض الآتي:

501	?	497	495	493	489	485	?	482	?
560	541	?	537	528	520	515	513	511	505

ف نجد أنَّ حساب مُعامل التغيُّر لهذه البيانات غير مُمكن بسبب عدم إمكانية حساب كلِّ من المتوسط ومن ثمَّ الانحراف المعياري (لاحظ هنا حتى المدى غير ممكن الحساب)، وأما لحساب مُعامل التشتت، فنجد أنَّ قيمة الرُّبَيعي الأول والثالث تساوي:

$$Q_1 = x_5 + \frac{1}{4} (x_6 - x_5) = 489 + \frac{1}{4} (493 - 489) = 450$$

$$Q_3 = x_{15} + \frac{3}{4} (x_{16} - x_{15}) = 520 + \frac{3}{4} (528 - 520) = 526$$

ومن ثمَّ (بحسب العلاقة [2,36]) قيمة مُعامل التشتت لهذه البيانات تساوي:

$$CD = \frac{526 - 450}{526 + 450} \times 100 = 7.79 \%$$

الآن، وقبل ختام بحث مقاييس التشتت سنقدِّم مفهوماً متعلّقاً بقيمة المتوسط والانحراف المعياري لمجموعة بيانات، ويُدعى **الدرجة المعياريّة** Standard Score حيث ينطوي تحت هذه التسمية معيارين مهمّين هما Z -score و T -score، وسنوضّحها من خلال الفقرات الآتية.

(٨, ٤, ٢) تعريف (الدرجة المعياريّة Z -score)

من أجل تعريف الدرجة المعياريّة Z سنميّز بين حالتين:

أ- إذا كانت x_1, x_2, \dots, x_n بيانات مُعطاة لعينة بمتوسط \bar{x} وانحراف معياري S ، فعندئذ **الدرجة المعياريّة** Z للقيمة x_i من هذه البيانات (والتي سنرمز لها بـ z_i) تُعرّف من خلال العلاقة الآتية:

$$Z_i := \frac{x_i - \bar{x}}{S} \quad ; i \in \mathbb{N}_n \quad [2,37-a]$$

ب- إذا كانت x_1, x_2, \dots, x_N بيانات مُعطاة لمجتمع بمتوسط μ وانحراف معياري σ ، فعندئذ **الدرجة المعياريّة** Z للقيمة x_i من هذه البيانات تُعرّف من خلال العلاقة الآتية:

$$Z_i := \frac{x_i - \mu}{\sigma} \quad ; i \in \mathbb{N}_n \quad [2,37-b]$$

لاحظ أنَّ قيمة هذا المعيار هي مُؤشّر على انحراف قيمة البيان الخام عن المتوسط، ومن ثمَّ فإنّها تُحدّد موقع البيان الخام من المتوسط اتّجهاً وبعداً، فالاتّجاه تُحدّده إشارة (+ أو -)، فإذا كانت قيمته موجبة فإنَّ ذلك يعني أنّه أكبر من المتوسط والعكس إذا كانت قيمته سالبة، وأملعلّب فتعني كبر القيمة المطلقة له، فكلما كبرت قيمته المطلقة ابتعدت القيمة x_i عن المتوسط.

من فوائد الدرجة المعياريّة أنّها تُعطينا صورة عن مكان الدرجة من المتوسط كما ذكرنا ذلك آنفاً، فعلى سبيل المثال يمكننا التعرّف على مستوى أداء طالب بالنسبة إلى زملائه، ولتوضيح ذلك سنقدّم المثال الآتي.

(١, ٨, ٤, ٢) مثال

في إطار الاختبارات العامة قامت وزارة التربية باختبار تدريبي لطلاب الصف الثالث الثانوي، ومن ثم أخذت عينة من مدرستين X و Y . بعد ذلك سُجِّت من كل مدرسة نتيجة لطالب واحد، فوجد أن الطالب A من المدرسة X قد حصل على 88 درجة، في حين أن الطالب B من المدرسة Y قد حصل على 83 درجة، فهل يمكننا الادعاء أن أداء الطالب A أفضل من أداء الطالب B ؟ في الواقع إن الإجابة على هذا السؤال تتطلب معرفة مستوى كل من هذين الطالبين في مدرسته لأنهما لا يخضعان لتعليم موحد سواء من حيث البيئة المحيطة بالطالب (من تفاعل ونشاط، أو من حيث المعلم، وحتى لو كانا من مدرسة واحدة فربما لم يُدرسوا من قبل معلم واحد أيضاً)، ولذلك فإن الإجابة على السؤال المطروح ليست بهذه البساطة، ويجب أن يؤخذ في الحسبان درجات الاختبار لزملاء كل واحد منهم، ومن ثم يُبحث في الإجابة بناءً على هذه المعطيات. فلو افترضنا الآن أن درجات الاختبار للطلاب في المدرسة X لها متوسط يساوي 85 درجة بانحراف معياري يساوي 3 درجات، وأن درجات الاختبار للطلاب في المدرسة Y لها متوسط يساوي 72 درجة بانحراف معياري يساوي 5 درجات، فعندئذ بحساب الدرجة المعيارية Z لكل من هذين الطالبين نجد الآتي:

$$Z_A = \frac{88-85}{3} = 1 \quad \& \quad Z_B = \frac{81-72}{5} = 1.8$$

وهكذا نجد أن الدرجة المعيارية Z للطالب B أعلى من الدرجة المعيارية Z للطالب A بفارق كبير (تكاد تقارب الضعف)، وهذا يعني أن أداء الطالب B أفضل من أداء الطالب A رغم أن نتيجة الطالب B أقل من نتيجة الطالب A . لهذا السبب قد تقوم وزارات التعليم العالي في بعض الدول بقبول معدلات (أو مجموع درجات) أقل من المطلوب للطلاب الناجحين في الثانوية العامة من المناطق النائية من أجل التسجيل في اختصاص ما، وذلك للأسباب التي أوضحنا بعضها في المثال السابق. من هنا يتبين لنا الفارق بين النتيجة الامتحانية والنتيجة المعيارية كمقياس للتفوق، وكذلك يتضح لنا من هذا المثال أن الدرجة المعيارية Z تفيدنا بالموضع النسبي لقيمة من مجموعة قيم مفترضة، وبما أنها قيمة مجردة من وحدة القياس فإنها تصلح للمقارنة بين الدرجات المعيارية Z لمجموعتين أو أكثر من البيانات التي لكل منها وحدة قياس مختلفة عن الأخرى.

(٢, ٨, ٤, ٢) ملاحظات

١- لو حُسبت الدرجة المعيارية Z لجميع عناصر العينة (أو المجتمع) فعندئذ سنلاحظ أن البيانات الناتجة عن هذه الدرجات المعيارية Z لها متوسط يساوي الصفر وانحراف معياري يساوي الواحد. في الحقيقة إذا أُجريت عمليات حسابية على قيمة عددية x بحيث يُصبح للقيمة الجديدة Z (بعد تنفيذ العمليات الحسابية على x) متوسط يساوي الصفر وانحراف معياري يساوي الواحد، فعندئذ يُقال عن هذه العمليات التي تم تطبيقها على x إنها عملية استيعار Standardization للقيمة العددية x ، بمعنى أن تحويل قيمة عددية x إلى قيمة Z لها متوسط يساوي الصفر وانحراف معياري يساوي الواحد تُدعى عملية استيعار، وهذه التسمية تبقى سارية المفعول حتى من أجل المتغيرات العشوائية وغير العشوائية أيضاً (نظر استيعار المتغير العشوائي الطبيعي في الفصل السادس).

٢- يأخذ على الدرجة المعيارية Z أنها عند قيمة الصفر يكون للبيان الذي استعيرت قيمته درجة القيمة الوسطى \bar{x} (أو μ)، ولذلك قد لا يكون معناها واضحاً لدى الكثير، وعلاوة على ذلك فقد تكون هذه الدرجة المعيارية Z سالبة أيضاً، وهذا بدوره يجعل تفسيرها من أجل بعض الحالات غير واضح أو غير ذي معنى، ولذلك اقترح تقديم مقياس آخر يتجاوز هذه السلبية.

إنَّ الدرجة المعيَّارة البديلة للدرجة المعيَّارة Z تُعرف باسم "الدرجة المعيَّارة T " T -score وتُعرف باسم الدرجة التَّائية (أخذ الحرف T من اسم واضع هذا المعيار عالم النفس الأمريكي ثورنديك (Edward Lee Thorndike (1874-1949) أيضاً والتي يُصيغها لنا التعريف الآتي.

(٢, ٤, ٩) تعريف (الدرجة المعيَّارة T T -score)

من أجل تعريف الدرجة المعيَّارة T سنميز بين حالتين:

أ - إذا كانت x_1, x_2, \dots, x_n بيانات مُعطاة لعينة بمتوسط \bar{x} وانحراف معياري S ، فعندئذٍ **الدرجة المعيَّارة T** لقيمة x_i من هذه البيانات (التي سنرمز لها بـ T_i) تُعرَّف من خلال العلاقة الآتية:

$$T_i := 10 \left(\frac{x_i - \bar{x}}{S} \right) + 50 \quad ; i \in N_n \quad [2,38-a]$$

ب - إذا كانت x_1, x_2, \dots, x_N بيانات مُعطاة لمجتمع بمتوسط μ وانحراف معياري σ ، فعندئذٍ تُعرَّف **الدرجة المعيَّارة T_i** للقيمة x_i من خلال العلاقة الآتية:


$$T_i := 10 \left(\frac{x_i - \mu}{\sigma} \right) + 50 \quad ; i \in N_n \quad [2,38-b]$$

(١, ٩, ٤, ٢) ملاحظات

١ - من التعريف السابق للقيمة التَّائية يتضح لنا أنه عندما تكون قيمة $Z = 0$ فإن $T = 50$ ، ومن ثمَّ نكون قد تخلصنا من قيمة الصفر كقيمة لهذا المعيار علاوةً على تجنب الكسور (أو التقليل منها) بسبب الضرب بالعدد 10، والشكل الآتي (١٠, ٢) يوضِّح لنا ذلك، ويظهر قيم كل من Z و T وما يقابلها من نسب عدد البيانات وفقاً لقاعدة تشبيشيف التجريبية على منحنى متناظر ومعتدل.

٢ - يُلاحظ أنَّ لـ T (كمُتغيِّر أو كدالة بالبيانات) متوسط يساوي 50 وانحراف معياري يساوي 10، وذلك لأنَّ لـ Z (كمُتغيِّر أو كدالة بالبيانات) متوسط يساوي 0 وانحراف معياري يساوي 1.

٣ - من الصيغة المقدَّمة للقيمة التَّائية نجد أنَّ $T = 10Z + 50$ وهي دالة خطية بـ Z ، ومن ثمَّ T هو تحويل خطي.



الشكل (١٠, ٢)

لتوضيح دلالة هذا المفهوم سنقدِّم المثال الآتي.

(٢, ٩, ٤, ٢) مثال

بالعودة إلى المثال السابق (١, ٨, ٤, ٢) سنقوم بحساب الدرجة التائية لكل من الطالبين A و B . حيث قمنا سابقاً بحساب كل من Z_A و Z_B ووجدنا أن $Z_A = 1$ و $Z_B = 1.8$ ، ومن ثم يكون لدينا:

$$T_A = 10(1) + 50 = 60 \quad \& \quad T_B = 10(1.8) + 50 = 68$$

وهكذا نجد أن الدرجة المعيارية T للطالب B أعلى من الدرجة المعيارية T للطالب A بفارق واضح (ولكن لم يعد يمكننا الادعاء أنه يقارب الضعف كما سبق في المعيار السابق)، وهذا يعني أن أداء الطالب B أفضل من أداء الطالب A رغم أن نتيجة الطالب B أقل من نتيجة الطالب A .

(٢, ٥) مقاييس الشكل للتوزيعات التكرارية

Form Measures of Frequency Distributions

لقد قدّمنا في الفصل الأول مناقشة بسيطة وموجزة حول أشكال التوزيعات، ولكن دون التطرق للمقاييس التي تُحدّد لنا نوعيّة هذه الأشكال. إنَّ المقاييس الجيدة والدقيقة لأشكال التوزيعات تعتمد وبشكل أساسي على مفهوم العزوم المركزية الذي سنقدّمه على النحو الآتي.

(١, ٥, ٢) العزوم المركزية لمجموعة بيانات Central Moments of Data Set:

من المفاهيم اللازمة لدراسة مقاييس الشكل للتوزيعات التكرارية ما يُعرف باسم **العزم المركزي من المرتبة r** لمجموعة بيانات، وهذا المفهوم يقدّمه لنا التعريف الآتي.

(١, ٥, ٢) تعريف (العزم المركزي من المرتبة r لمجموعة بيانات) Central Moment of Order r of Data Set

ليكن r عدداً صحيحاً موجباً كيفياً ولكن مثبّثاً، فعندئذ لتعريف العزم المركزي من المرتبة r لبيانات مُعطاة سنناقش الحالتين الآتيتين:

أولاً: من أجل البيانات الخام:

أ- إذا كانت x_1, x_2, \dots, x_n بيانات عينة متوسطةها \bar{x} ، فإنَّ **العزم المركزي من المرتبة r** لهذه البيانات سنرمز له بـ $S^{(r)}$ ويُحسب بالعلاقة الآتية:

$$S^{(r)} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^r \quad [2,39-a]$$

ب- إذا كانت x_1, x_2, \dots, x_N بيانات مجتمع متوسطه μ ، فإنَّ العزم المركزي من المرتبة r لهذه البيانات سنرمز له بـ $\sigma^{(r)}$ ويُحسب بالعلاقة الآتية:

$$\sigma^{(r)} = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^r \quad [2,39-b]$$

ثانياً: من أجل البيانات المُجمّعة:

أ- إذا كانت مجموعة البيانات المُعطاة هي بيانات عينة مُجمّعة (أو مُحمّلة، أو مبوّية، أو مصبوبة) في جدول توزيع تكراري بـ k فئة كما في الجدول (١, ٢)، وكان متوسطها يساوي \bar{x} ، فعندئذ يُحسب العزم المركزي $S^{(r)}$ لهذه البيانات بالعلاقة الآتية:

$$S^{(r)} = \frac{1}{(\sum f_i) - 1} \sum_{i=1}^k f_i (x_i - \bar{x})^r \quad [2,40-a]$$

ب- إذا كانت مجموعة البيانات المُعطاة هي بيانات مجتمع ومُحمَّلة في جدول توزيع تكراري بـ k فئة كما في الجدول (١، ٢)، وكان متوسطها μ ، فعندئذ يُحسب العزم المركزي $\sigma^{(r)}$ بالعلاقة الآتية:

$$\sigma^{(r)} = \frac{1}{(\sum f_i) - 1} \sum_{i=1}^k f_i (x_i - \mu)^r \quad [2,40-b]$$

(٢، ١، ٢) ملاحظات

١- في الحالة الخاصة عندما يكون $r = 2$ نلاحظ أنَّ العزم المركزي من المرتبة الثانية للبيانات هو التباين لهذه البيانات، ولذلك يُكتب وفي هذه الحالة الخاصة $S^{(2)} = S^2$ و $\sigma^{(2)} = \sigma^2$ للدلالة على أنَّ العزم المركزي من المرتبة الثانية هو مقدار غير سالب.

٢- هنا يجب الانتباه إلى أنَّه في الحالة العامة لدينا $\sigma^{(r)} \neq \sigma^r$ وكذلك $S^{(r)} \neq S^r$ لأنَّ $0 \leq \sigma^r$ وبالمثل $0 \leq S^r$ دوماً، في حين أنَّ المقدار $\sigma^{(r)}$ (أو $S^{(r)}$) قد يكون سالباً من أجل القيم الفردية لـ r ، والمثال الآتي يوضح لنا ذلك.

(٢، ١، ٣) مثال

لتكن لدينا بيانات عينة مقدَّمة كما يلي:

9 5 8 4 7 4 8 4 8 4 8 5 6 9 7

ف نجد أنَّ قيمة المتوسط لهذه البيانات هو $\bar{x} = 6.4$ ، ولنقم بحساب S^5 و $S^{(5)}$ مستعينين بالجدول الآتي:

الجدول (٢، ٩)

i	x_i	$(x_i - 6.4)^2$	$(x_i - 6.4)^5$	i	x_i	$(x_i - 6.4)^2$	$(x_i - 6.4)^5$
1	9	6.76	118.8138	9	8	2.56	10.48576
2	5	1.96	-5.37824	10	4	5.76	-79.6262
3	8	2.56	10.48576	11	8	2.56	10.48576
4	4	5.76	-79.6262	12	5	1.96	-5.37824
5	7	0.36	0.07776	13	6	0.16	-0.01024
6	4	5.76	-79.6262	14	9	6.76	118.8138
7	8	2.56	10.48576	15	7	0.36	0.07776
8	4	5.76	-79.6262	sum	96	51.6	-49.5456

لتسهيل العمليات الحسابية حيث نجد أنَّ قيمة التباين لهذه البيانات تساوي:

$$S^2 = \frac{1}{14} \sum_{i=1}^{15} (x_i - 6.4)^2 = \frac{51.6}{14} = 3.6857$$

ومنه تكون قيمة الانحراف المعياري $S = 1.9198$ ، ومن ثمَّ $S^5 = 26.0798$ ، وأمَّا العزم المركزي من المرتبة 5 لهذه البيانات فنجد أنه يساوي:

$$S^{(5)} = \frac{1}{14} \sum_{i=1}^{15} (x_i - 6.4)^5 = \frac{-49.5456}{14} = -3.539$$

وهكذا يكون لدينا $S^{(5)} \neq S^5$ ، وهذا يؤكد صحة دعوانا.

الآن، وقبل البدء في تقديم بعض مقاييس الشكل يجب أن نتفهم السبب وراء استخدام هذه المقاييس، وذلك لأنه يجب أن نعلم متى يلجأ الباحث (أو الدارس لمسألة إحصائية ما) إلى حساب مقاييس الشكل.

لاحظنا فيما سبق أن التوزيع يكون ملتوياً إذا تراكمت البيانات عند أحد أطراف التوزيع دون الطرف الآخر، وبالطبع توجد أسباب عديدة لذلك، فعلى سبيل المثال:

- إذا كان اختبار مقرر دراسي ما غاية في السهولة أو غاية في الصعوبة فإن قيم الدرجات ستتراكم على الجهة اليمنى أو اليسرى على الترتيب، ومن ثم توزيع الدرجات لهذا الاختبار سيكون ملتوياً.
- كذلك بعض المقاييس الفسيولوجية كمقاييس زمن الاستجابة وسرعة الأداء تحتمل أن يكون لها توزيعات ملتوية.
- يمكن لتوزيع البيانات المقاسة على ميزان فتراتي أو رتبي أن يكون ملتوياً أيضاً.

نشير هنا إلى أنه إذا كانت البيانات مجمعة في فئات وكان توزيعها ملتوياً فإنه يفضل استخدام الوسيط كمقياس للنزعة المركزية، والمدى الرئعي كمقياس للتشتت، ولكن بما أن الكثير من الدراسات الإحصائية تفترض أن توزيع الدرجات الخام لمتغير ما يكون معتدلاً ومتناظراً وليس ملتوياً، فإن قيمة معامل الالتواء ستكون صفراً أو قريبة جداً من الصفر، وفي هذه الحالة ينطبق الوسيط على المتوسط ولا داعي لتطبيق مقياس إحصائي لبيان أن التوزيع ليس ملتوياً. لكن الباحث يمكنه تحديد درجة الالتواء ويقرر إن كان لابد من إجراء بعض التصحيحات (مثل تصحيح دقة جهاز القياس المستخدم) قبل أن يستمر في تحليل بياناته، وفي حالات أخرى لكي يجعل الباحث توزيع الدرجات قريباً من التناظر (إذا لم يكن كذلك)، فربما يلجأ إلى استخدام نوع من التحويلات غير الخطية على البيانات، غير أن هذه التحويلات تؤدي إلى مشكلات من نوع آخر عند تفسير نتائج البيانات أيضاً.

في الواقع نجد أن طبيعة البحث، ونوع المتغيرات موضع الدراسة، وحجم العينة تعد جميعها من العوامل التي يجب أن تأخذ في الحسبان قبل أن يُقرر إن كان لابد من حساب مقاييس الالتواء والتفلطح. علاوة على ما سبق يجب أن يدرك الباحث أن التوزيعات الملتوية لكثير من المتغيرات قد تكون مُصطنعة كما هو الحال لدى الدراسات النفسية والتربوية والاجتماعية، وذلك لأنه يندر أن تكون الوحدات المستخدمة في بناء المقاييس لهذه الدراسات متساوية حيث الكثير من هذه المتغيرات تُقاس بعدد من العبارات التي يعطي كل فرد رأيه فيها، أو عدد الإجابات الصحيحة من الأسئلة التي تطرح عليهم. في مثل هذه الحالات يُعين شكل التوزيع الناتج إلى حد كبير بالنسبة المئوية للعبارات التي أجيب عنها، أو بصعوبة الأسئلة المقدمة، فإذا كانت الأسئلة متوسطة الصعوبة فإننا ستوقع توزيعاً متناظراً لقيم البيانات، وأما إذا كانت الأسئلة سهلة فإن قيم البيانات ستتراكم عند النهاية العليا للتوزيع، وفي حال كانت الأسئلة صعبة فإن قيم البيانات ستتراكم عند النهاية السفلى للتوزيع كما ذكرنا ذلك سابقاً.

إذاً، وفي حال غياب وحدات قياس متساوية لأداة القياس لا يمكننا حقيقة القول إن التوزيع متناظر أو ملتوي، وكل ما يمكننا قوله هو أن شكل التوزيع سوف يعتمد على وحدات القياس المستخدمة فقط.

لنعد الآن إلى تقديم بعض العلاقات التي تساعدنا في حساب مقاييس الالتواء والتفلطح لتوزيع ما. حيث نعلم من الفصل السابق أن أشكال التوزيعات التكرارية تُقسم إلى صنفين:


الأول: يتعلّق بمسألة تناظر شكل التوزيع من عدمه، وهذه تندرج تحت مفهوم الالتواء للتوزيع.

الثاني: يتعلّق بوضع قمة التوزيع، فهل هي منخفضة (أي انبساط شكل التوزيع) أم أنها مرتفعة (أي تدبذب شكل التوزيع) أم معتدلة (ليست منخفضة ولا مرتفعة)؟ وهذه الأخيرة تندرج تحت مفهوم التفلطح للتوزيع.


إنَّ المقاييس التي تقدّم أجوبة على هذه التساؤلات تدرج تحت ما يُعرف باسم **مقاييس الشكل** للتوزيعات التي سنبدأها بمقاييس الالتواء.

(٢, ٥, ٢) مقاييس الالتواء Skewness measures


من المعلوم (وكما لاحظنا لدى بعض التوزيعات التكرارية) أنَّ التوزيع قد يكون له أحد الأشكال الثلاثة الآتية:
أ - ملتوٍ نحو اليمين، أي له ذيل منبسط نحو اليمين أكثر منه نحو اليسار.



ب - ملتوٍ نحو اليسار، أي له ذيل منبسط نحو اليسار أكثر منه نحو اليمين.



ج - متناظر، أي الجزء الأيمن من التوزيع (بدءاً من قِمة التوزيع) هو صورة مرآة لجزئه الأيسر.



لذلك سنقدّم فيما يلي بعض المقاييس التي تحدّد لنا إن كان التوزيع متناظراً أم ملتوياً، وفي حال كان ملتوياً نعيّن مقدار هذا الالتواء وجهته. إنَّ أشهر وأدقّ المقاييس الخاصّة بالالتواء هو مُعامل الالتواء العزومي الذي يقدّمه لنا التعريف الآتي.

(٢, ٥, ٢, ١) تعريف (مُعامل الالتواء العزومي Moment Coefficient of Skewness):

لنفترض أنَّ لدينا بيانات مُعطاة، فعندئذ:

أ - إذا كانت هذه البيانات لعيّنة، وكان انحرافها المعياري يساوي S ، فإنَّ مُعامل الالتواء العزومي لهذه البيانات سنرمز له بـ S ،
ويحسب بالعلاقة الآتية:

$$S = \frac{S^{(3)}}{S^3}$$

[2-41-a]

فلاحظ هنا أنه يجب أن يكون $0 < S$ ، وهذا محقق في جميع الحالات التي يكون فيها حجم العينة أكبر أو يساوي 2، ومنهما قيمتان على الأقل مختلفتان عن بعضهما.

ب- إذا كانت هذه البيانات لمجتمع، وكان انحرافها المعياري يساوي σ ، فإن **معامل الالتواء العزومي** لهذه البيانات سنرمز له بـ \mathcal{S} أيضاً، ويحسب بالعلاقة الآتية:

$$\mathcal{S} = \frac{\sigma^{(3)}}{\sigma^3} \quad [2,41-b]$$

وفي كلا الحالتين السابقتين تُناقش قيمة \mathcal{S} على النحو الآتي:

- ١- إذا كان $0 < \mathcal{S}$ فعندئذ يكون توزيع البيانات ملتوياً نحو اليمين، أو يُقال إنَّ توزيع البيانات موجب الالتواء.
- ٢- إذا كان $0 > \mathcal{S}$ فعندئذ يكون توزيع البيانات ملتوياً نحو اليسار، أو يُقال إنَّ توزيع البيانات سالب الالتواء.
- ٣- إذا كان $\mathcal{S} = 0$ فعندئذ يكون توزيع البيانات متناظراً، أو يُقال إنَّ توزيع البيانات متماثل.

(١, ١, ٢, ٥, ٢) ملاحظات

١- إذا كانت البيانات المُعطاة لعينة، فعندئذ يمكن استخدام العلاقة الآتية أيضاً لحساب معامل الالتواء:

$$\mathcal{S} = \frac{\sqrt{n(n-1)}}{n-2} \cdot \frac{S^{(3)}}{S^3} \quad [2,41-c]$$


ولكن تبين أنه من الأفضل استخدام العلاقة الآتية لحساب معامل الالتواء العزومي:

$$\mathcal{S} = \frac{n^2}{(n-1) \cdot (n-2)} \cdot \frac{S^{(3)}}{S^3} \quad [2,41-d]$$

لاحظ هنا يجب أن يكون $3 \leq n$ ، وهذا يجعل قيمة $0 < \mathcal{S}$ مُحَقَّقة. إنَّ الصيغة الأخيرة [2-41-d] تستخدم في بعض البرامج الإحصائية (مثل: SPSS، Minitab، ...) لحساب معامل الالتواء من أجل بيانات العينات والمجتمعات على حدٍ سواء، بمعنى أنه من أجل هذه الحالة تقوم بعض البرامج بالتعامل مع البيانات على أنها بيانات عينة.

(٢, ٥, ٢, ٢) **معامل بيرسون للالتواء Person's Coefficient of Skewness**

لو أمعنا النظر في العلاقات المختلفة لحساب معامل الالتواء العزومي فإننا نلاحظ أنها تتطلب تنفيذ عمليات حسابية مطوّلة للحصول على النتيجة، ولهذا سنقدم علاقات أكثر بساطة (ولو أنها أقل دقة) لحساب قيمة معامل الالتواء. إنَّ الفكرة لهذه المقاييس التي سنقدمها مبنية على الوضع النسبي لقيم المتوسط، والوسيط، والمنوال لدى حالات مختلفة من الالتواء، توضيحها لنا الأشكال الآتية (من أجل توزيعات مستمرة):



الشكل (٢, ١٢)

وكما نلاحظ من الشكل السابق أنه عندما يكون التوزيع ملتوفاً للمتوسط سوف ينزاح باتجاه ذيل التوزيع أكثر من الوسيط، والوسيط سينزاح باتجاه ذيل التوزيع أكثر من المنوال (علماً أن قيمة المنوال توافق قمة التوزيع دوماً)، ومن ثم فممن المناسب أن تُستخدم الفروق بين هذه القيم (المتوسط، والوسيط، والمنوال) لصنع مقياس للالتواء، ولكن مقدار هذا الفرق يعتمد على مقدار تشتت (أو انتشار) البيانات أيضاً؛ ولذا فمن الضروري أن نتخلص من تأثير هذا التشتت لكي نحصل على مقياس دقيق للالتواء، ويتم ذلك بقسمة ناتج الفرق على قيمة الانحراف المعياري.

لقد قام الإحصائي الإنكليزي بيرسون (Karl Pearson (1875-1936) (كان رائداً في الإحصاء ومبتكراً لاختبار كاي مربع) باستخدام هذه الميزات المذكورة آنفاً لصياغة ما يُعرف باسم مُعامل بيرسون للالتواء الذي قدّمه على النحو الآتي:

بفرض أنه لدينا بيانات عينة مُعطاة بمتوسط \bar{x} ومنوال \hat{x} وانحراف معياري S ، فعندئذ يُحسب مُعامل الالتواء لهذه البيانات بالعلاقة الآتية:

$$S_p = \frac{\bar{x} - \hat{x}}{S} \quad [2,42-a]$$

وتُعرف هذه القيمة باسم مُعامل بيرسون للالتواء، وتناقش كما سبق لدى مُعامل الالتواء العزومي، ولكن نعلم أنه قد يتعذر علينا حساب المنوال \hat{x} في بعض الحالات، وفي حالات أخرى قد يكون للبيانات أكثر من منوال، فعندئذ العلاقة السابقة لا تفيدنا بشيء، ولهذا السبب يُلجأ إلى استخدام العلاقة الآتية كبديل للعلاقة السابقة في حساب مُعامل الالتواء:

$$S_p = \frac{3(\bar{x} - \tilde{x})}{S} \quad [2,42-b]$$

وتناقش هذه القيمة S_p وفقاً لما سبق وتحمل اسم العلاقة السابقة نفسه أيضاً.

(١, ٢, ٢, ٥) ملاحظات

١- إذا كانت البيانات لمجتمع إحصائي بمتوسط μ ، منوال $\hat{\mu}$ ، وسيط $\tilde{\mu}$ وانحراف معياري σ ، فعندئذ يصبح للعلاقين السابقتين [2-42-a] و [2-42-b] العرضين الآتيين على الترتيب:

$$S_p = \frac{\mu - \hat{\mu}}{\sigma} \quad [2,42-c]$$

$$S_p = \frac{3(\mu - \tilde{\mu})}{\sigma} \quad [2,42-d]$$

٢- إن القيمة التي نحصل عليها من هذا المقياس هي قيمة عددية مجردة من وحدة القياس.

(٢, ٥, ٢, ٣) مُعامل باولي للالتواء Bowley's Coefficient of Skewness:

لو أمعنا النظر في العلاقات السابقة لحساب مُعامل الالتواء فإننا نلاحظ أنها تصبح عديمة التطبيق في حال فقدان بعض البيانات (ومن ثم عدم إمكانية حساب العزوم المركزية للبيانات) أو وجود قيم متطرفة تؤدي إلى إعطاء تقدير غير مقبول للمتوسط الحسابي \bar{x} ، ولهذا يجب البحث في علاقات بديلة تُمكننا من تعيين الالتواء وحساب مقداره في مثل هذه الحالات.

في الواقع يمكن اللجوء إلى استخدام الرُّبيَّيات في مثل هذه الحالات إذا كانت البيانات المفقودة لا تؤثر في حساب الرُّبيَّيات، وهذا ما قام به الإحصائي والاقتصادي البريطاني **باولي** Sir Arthur Lyon Bowley (1869-1957) (وكان رائداً في استخدام تقنيات أخذ العينات في المسوح الاجتماعية) حيث قدّم ما يُعرف باسم مُعامل باولي للالتواء، وذلك على النحو الآتي:


بفرض أنّه لدينا بيانات مُعطاة رُّبيّياته Q_1 ، Q_2 و Q_3 ، فعندئذ يُمكن حساب مُعامل الالتواء لهذه البيانات باستخدام العلاقة الآتية:

$$S_B := \frac{(Q_3 - Q_2) - (Q_2 - Q_1)}{Q_3 - Q_1} = \frac{Q_3 + Q_1 - 2Q_2}{Q_3 - Q_1} \quad [2,43]$$

وتُعرف هذه القيمة باسم **مُعامل باولي للالتواء** وتُناقش قيمته S_B وفقاً لما سبق أيضاً.

إنّ العلاقة السابقة تُفسّر هندسياً على النحو الآتي:

نعلم أنّ مساحة المدرج التكراري بين الرُّبيّي الأول والثاني تساوي ربع المساحة الكلية، وبالمثل مساحة المدرج التكراري بين الرُّبيّي الثاني والثالث هي ربع المساحة الكلية أيضاً، ومن ثمّ ستكون من أجل البيانات ذات الالتواء الموجب المسافة بين الرُّبيّي الثالث والثاني أقصر من المسافة بين الرُّبيّي الأول والثاني، وعلى العكس في حالة الالتواء نحو اليسار، أي إن المسافة بين الرُّبيّي الثالث والثاني أقصر من المسافة بين الرُّبيّي الأول والثاني (انظر الشكل الآتي):



الشكل (١٣، ٢)

ومن ثمّ يمكن استخدام الفرق $(Q_3 - Q_2) - (Q_2 - Q_1)$ للتعبير عن الالتواء، ومن أجل إلغاء تأثير تشتت البيانات في قيمة الالتواء والتخلص من وحدة القياس بأن واحد قام بالتقسيم على المدى الرُّبيّي $Q_3 - Q_1$ ليحصل بذلك على العلاقة [2,43].

(٤، ٢، ٥، ٢) مثال

١- أخذت عيّنة من الحمام الزاجل ورُقيت أعمارها، فكانت النتائج كما في مجموعة البيانات الآتية (مقدراً بالسنة):

2	9	4	11	11	8	14	13	4	6	9
4	8	9	15	12	7	3	7	10	5	12
3	4	1	8	8	6	6	2	8	10	

وبعد ترتيبها تصاعدياً يصبح لها العرض الآتي:

1	2	2	3	3	4	4	4	4	5	6
6	6	7	7	8	8	8	8	8	9	9
9	10	10	11	11	12	12	13	14	15	

ف نجد أنّ قيمة المتوسط والوسيط لهذه البيانات هي على الترتيب:

$$\bar{x} = \frac{1}{32} \sum_{i=1}^{32} x_i = \frac{239}{32} = 7.469$$

$$\tilde{x} = \frac{x_{\frac{n}{2}} + x_{\frac{n}{2}+1}}{2} = \frac{x_{16} + x_{17}}{2} = \frac{8+8}{2} = 8 = Q_2$$

$$\hat{x} = 8$$

وَأَمَّا قِيَمَتِي الرَّيْعِيِّ الْأَوَّلِ وَالثَّالِثِ فَهِيَا:

$$Q_1 = x_8 + 0.25(x_9 - x_8) = 4 + 0.25(4 - 4) = 4$$

$$Q_3 = x_{24} + 0.75(x_{25} - x_{24}) = 10 + 0.75(10 - 10) = 10$$

وذلك لَأَنَّهُ لَدِينَا:

$$q_1 = \frac{n+1}{4} = \frac{32+1}{4} = 8.25 \quad \& \quad q_3 = \frac{3(n+1)}{4} = \frac{99}{4} = 24.75$$

وَأَمَّا التَّبَايِنُ لِهَذِهِ الْبَيَانَاتِ فَنَجِدُهُ يَسَاوِي:

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{419.9688}{31} = 13.547$$

وَمِنْ ثَمَّ تَكُونُ لَدِينَا قِيَمَةُ الْانْحِرَافِ الْمَعْيَارِيِّ $S = 3.681$. أَخِيرًا نَجِدُ أَنَّ الْعِزْمَ الْمَرْكَزِيَّ مِنَ الْمَرْتَبَةِ الثَّلَاثَةِ لِهَذِهِ الْبَيَانَاتِ يَسَاوِي:

$$S^{(3)} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^3 = \frac{224.8081}{31} = 7.252$$

وَهَكَذَا يَكُونُ لِمُعَامِلِ الْاَلْتَوَاءِ الْعِزْمِيِّ لِلْبَيَانَاتِ الْمُعْطَاةِ الْقِيَمَةُ الْآتِيَةُ:

$$\mathcal{S} = \frac{S^{(3)}}{S^3} = \frac{7.252}{49.877} = 0.144$$

أَوْ بِاسْتِخْدَامِ الْعِلَاقَةِ [2,41, d] (الصِّيغَةُ الْمَعْدَلَةُ لِمُعَامِلِ الْاَلْتَوَاءِ) نَجِدُ لِمُعَامِلِ الْاَلْتَوَاءِ الْعِزْمِيِّ لِلْبَيَانَاتِ الْمُعْطَاةِ الْقِيَمَةُ الْآتِيَةُ:

$$\mathcal{S} = \frac{n^2}{(n-1) \cdot (n-2)} \cdot \frac{S^{(3)}}{S^3} = \frac{1024}{930} \times 0.144 = 0.160$$

فَنَجِدُ مِنَ الصِّيغَتَيْنِ السَّابِقَتَيْنِ لِمُعَامِلِ الْاَلْتَوَاءِ الْعِزْمِيِّ أَنَّ تَوَازِيْعَ الْبَيَانَاتِ مِلْتَوْنِ نَحْوَ الْيَمِينِ بِشَكْلِ طَفِيفٍ. أَمَّا إِذَا اسْتِخْدَامْنَا مُعَامِلَ بِيرْسُونِ لِلْاَلْتَوَاءِ (الْعِلَاقَةُ [2,42-a]) فَإِنَّا سَنَجِدُ:

$$\mathcal{S}_P = \frac{\bar{x} - \hat{x}}{S} = \frac{7.469 - 8}{3.681} = -0.1443$$

أَوْ بِاسْتِخْدَامِ الْعِلَاقَةِ [2,42, b] فَنَجِدُ:

$$\mathcal{S}_P = \frac{3(\bar{x} - \tilde{x})}{S} = \frac{3(7.469 - 8)}{3.681} = -0.433$$

وَأَخِيرًا إِذَا اسْتِخْدَامْنَا مُعَامِلَ بَاوْلِي لِلْاَلْتَوَاءِ يَكُونُ لَدِينَا:

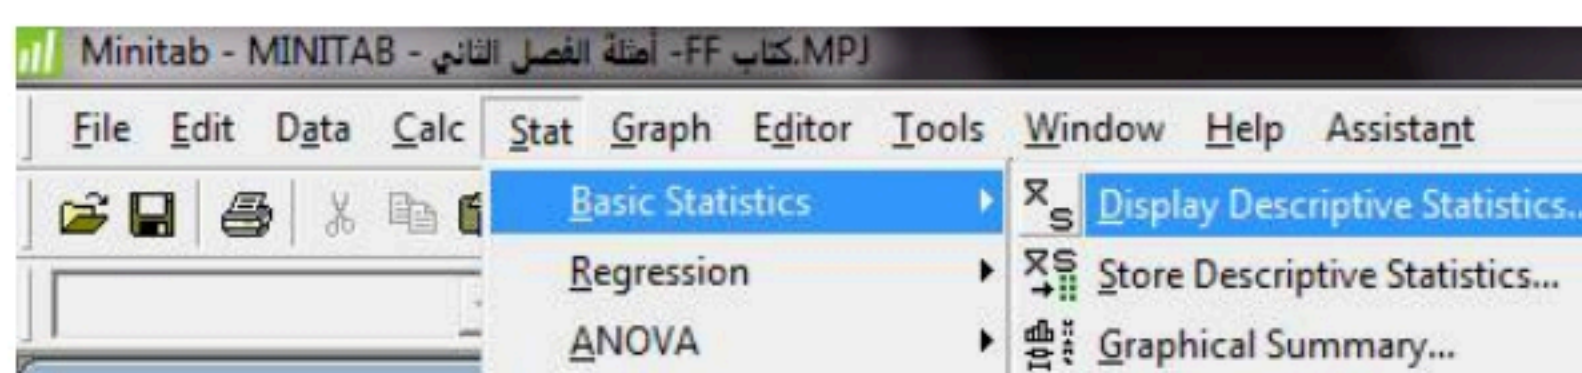
$$S_B = \frac{Q_3 + Q_1 - 2Q_2}{Q_3 - Q_1} = \frac{10 + 4 - 16}{10 - 4} = -0.3333$$

وهذه الصيغ الثلاث الأخيرة تُظهر لنا أنَّ توزيع البيانات ملتونحو اليسار بشكل طفيف، وبما أنَّ هذه النتائج متناقضة مع نتائج مُعاملات الالتواء العزومية فإنَّنا نأخذ بقيم مُعاملات الالتواء العزومية لأنَّها الأكثر دقَّة. وهكذا نخلص إلى الملاحظات الآتية.

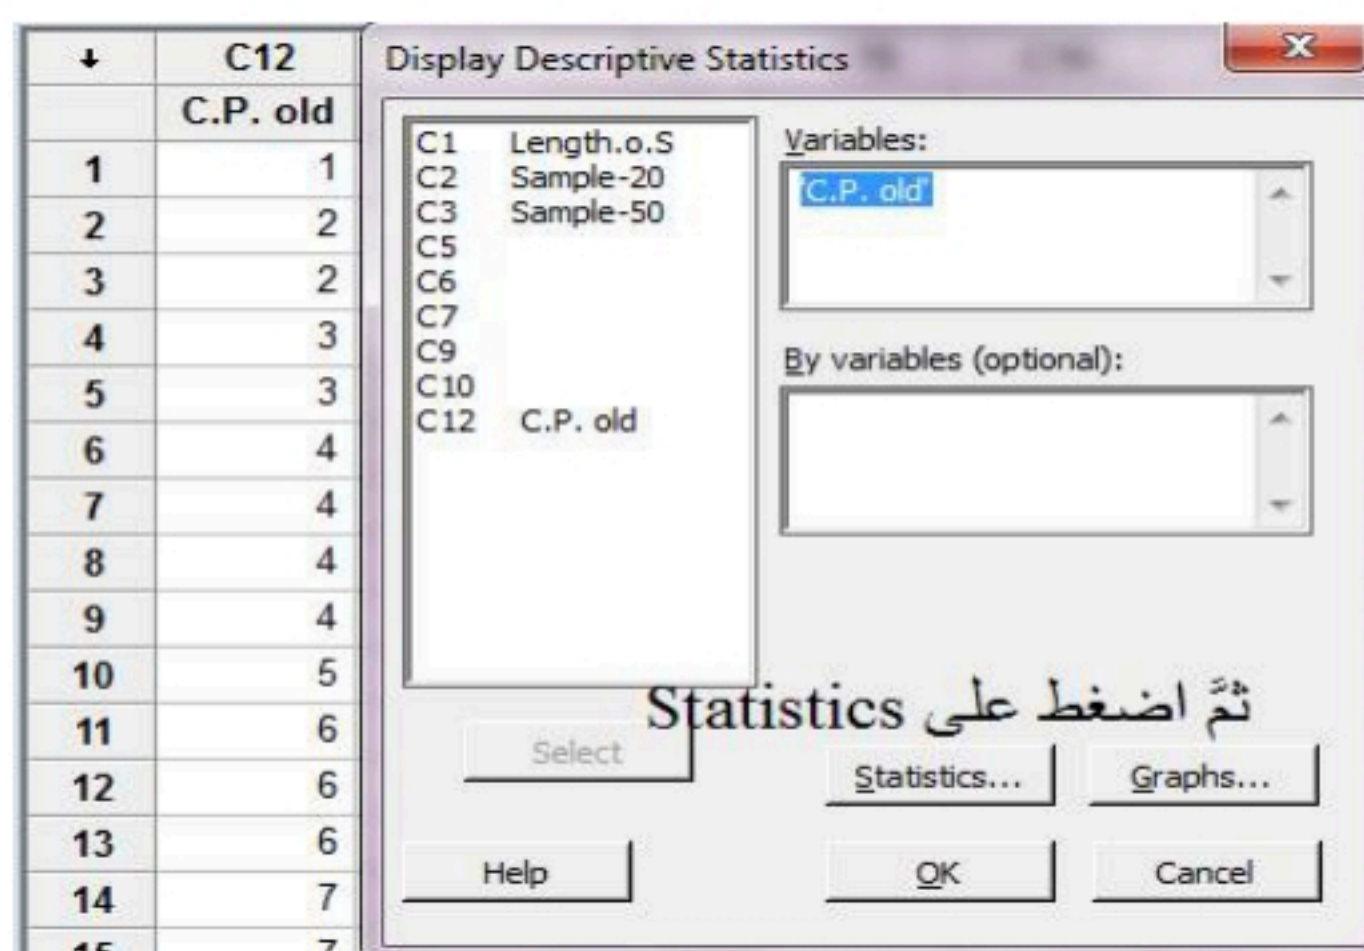
(٢, ٥, ٢, ٥) ملاحظات

١- بما أنَّ مقاييس الالتواء لـ بيرسون و باولي ليست دقيقة بما يكفي إذا ما قورنت بقيمة مُعامل الالتواء العزومي، فإنَّه إذا قمنا باستخدام أحد هذه المقاييس (مقاييس بيرسون و باولي) ولاحظنا أنَّ التوزيع متناظر أو ملتو بشكل طفيف جداً فإنَّه من الأفضل (بل الواجب في حال الضرورة) اللجوء إلى استخدام مُعامل الالتواء العزومي لإظهار حقيقة التناظر أو الالتواء. بمعنى أنَّه أدق القيم لمُعامل الالتواء هي تلك التي تُحسب باستخدام مُعامل الالتواء العزومي، يليها مُعامل بيرسون للالتواء، ومن ثمَّ مُعامل باولي للالتواء.

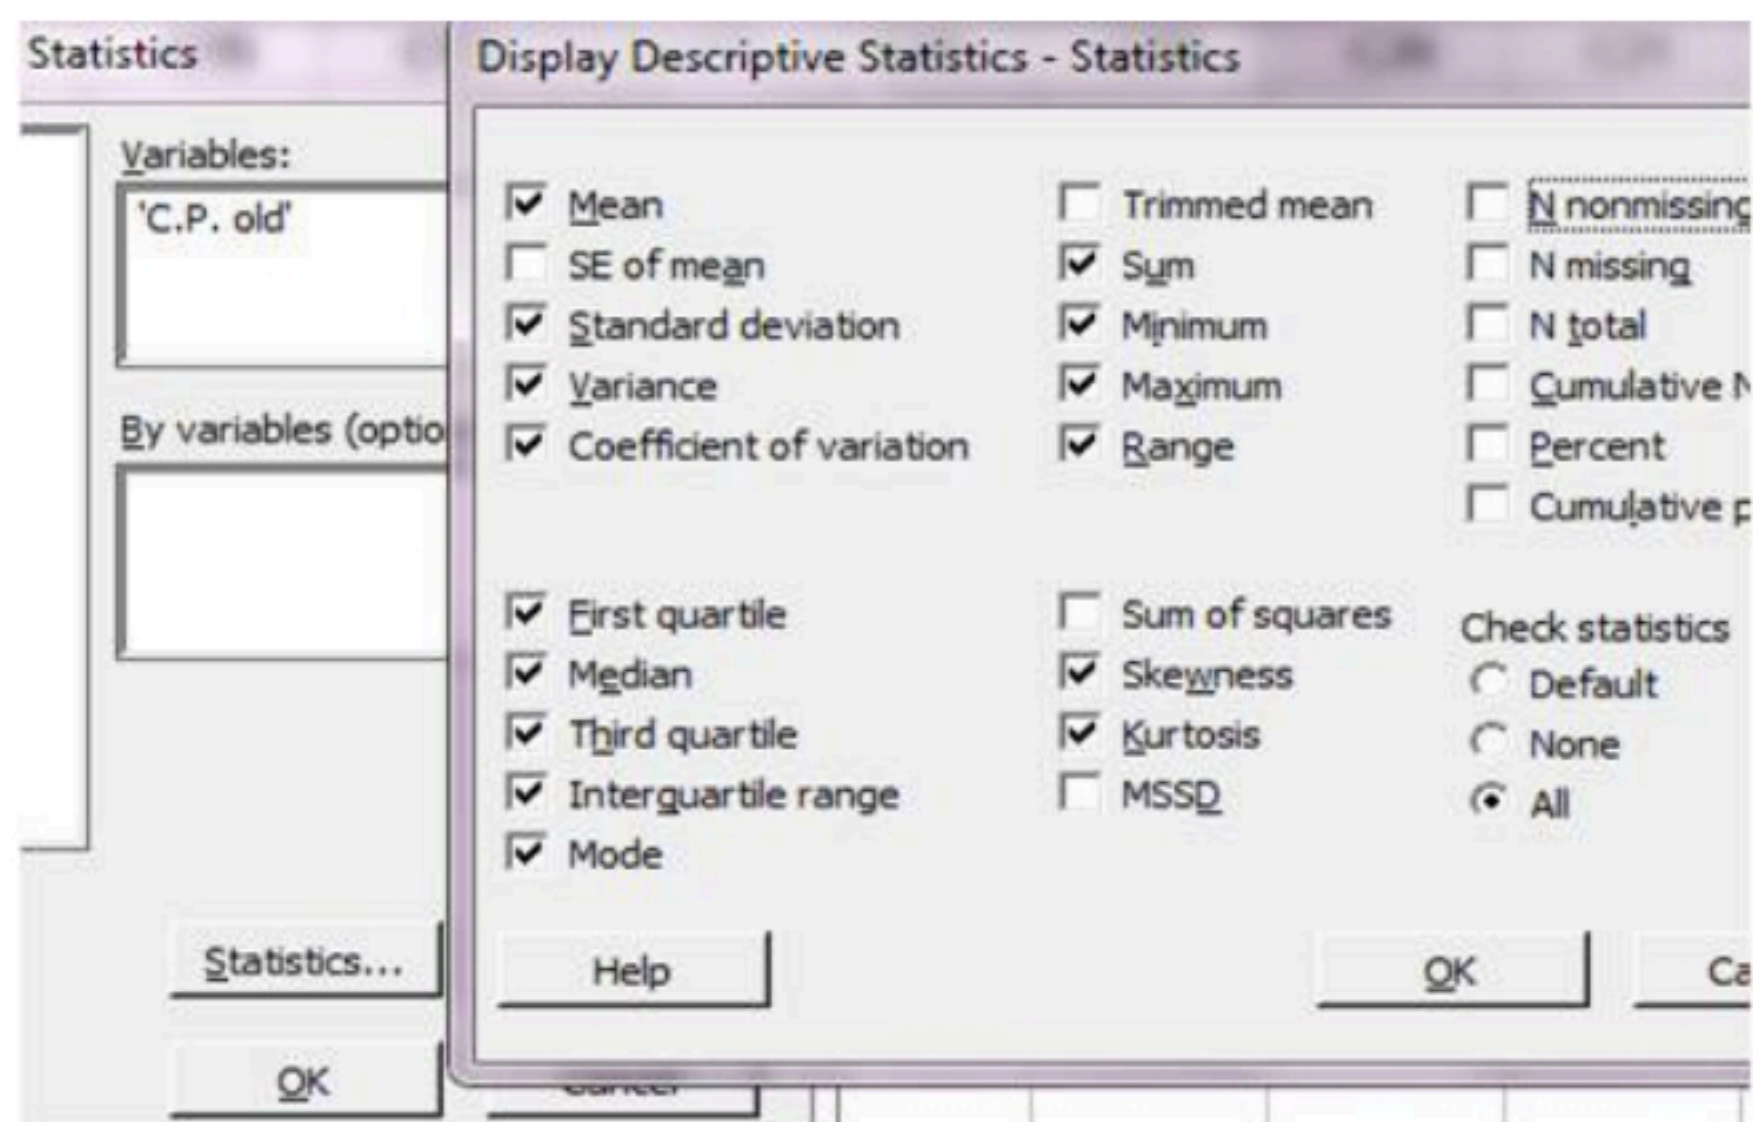
٢- من الممكن استخدام برنامج Minitab للحصول على النتائج السابقة، وذلك وفقاً للخطوات الموضَّحة بالعروض الآتية:



ومن ثمَّ نضغط على Statistics



وبعد ذلك فَعَلْ النوافذ التي ترغب بها في اللوحة التالية ومن ثمَّ اضغط OK ثمَّ OK على اللوحة السابقة:




فتحصل على التقرير الآتي (قمنا بالتعديل على التنسيق فقط لإظهاره بشكل واضح):

Descriptive Statistics:

Mean	StDev	Variance	CoefVar	Sum	Minimum	Q ₁	Median	Q ₃	Maximum
7.469	3.681	13.547	49.28	239.0	1.0	4.0	8.0	10.0	15.0
Range	IQR	Mode	Mode	Skewness	Kurtosis				
14.0	6.0	8	5	0.16	-0.71				

(٢, ٥, ٣) مقاييس التفلطح Kurtosis Measures

من المعلوم أنه من أجل بيانات محدّدة ستكون المساحة تحت الشكل الممثل للتوزيع (مدرج تكراري، أو مضلع تكراري، أو منحنى تكراري) تساوي مقدّاراً ثابتاً، ولهذا السبب، فإنه إذا كانت تشتت البيانات كبيراً فإن ذلك سيوافق امتداداً لأحد ذيلي التوزيع (على الأقل)، ومن ثمّ انخفاضاً لقمة التوزيع. وعلى العكس، فإذا كانت تشتت البيانات صغيراً فإن ذيلي التوزيع سوف ينبسطان مقترين من المتوسط، ومن ثمّ سيؤدي ذلك إلى ارتفاع قمة التوزيع، والشكل الآتي (٢, ١٤) يوضّح ذلك.



الشكل (٢, ١٤)

الآن من أجل قياس درجة هذا الانخفاض أو الارتفاع لقمة التوزيع وما يرافق ذلك لأطراف التوزيع اعتمدت مقاييس عديدة سُميت بمقاييس **التفلطح** (أو **مقاييس التفرطح**)، علماً أنَّ تفلطح توزيع ما يُقاس بمقدار **انبساط** أو **تدبب** المنحنى التكراري لتوزيع البيانات، ولهذا كان لا بدَّ من إعطاء مقاييس عددية تُحدّد مقدار هذا الانبساط أو التدبب. في هذا الصدد اقترح **بيرسون** العلاقة الآتية لقياس درجة تفلطح توزيع ما.

(١, ٣, ٥, ٢) **معامل بيرسون للتفلطح** **Person's Coefficient of Kurtosis**

نفترض أنَّ لدينا بيانات مُعطاة لعينة انحرافها المعياري S ، فعندئذ يُدعى المقدار الآتي:

$$\mathcal{K} := \frac{S^{(4)}}{S^4} - 3 \quad [2,44-a]$$

معامل التفلطح العزومي للبيانات.

أمّا إذا كانت البيانات المُعطاة لمجتمع بانحراف معياري σ ، فعندئذ يُحسب مُعامل التفلطح العزومي لهذه البيانات من خلال العلاقة الآتية:

$$\mathcal{K} := \frac{\sigma^{(4)}}{\sigma^4} - 3 \quad [2,44-b]$$

إنَّ العلاقتين السابقتين [2,44-a] و [2,44-b] هما الأصل في تعريف مُعامل التفلطح العزومي، وقيمة هذا المُعامل \mathcal{K} تُناقش على النحو الآتي:

١- إذا كان $\mathcal{K} < 0$ ، فعندئذ يكون التوزيع **مُدبباً**، ويزداد تدبباً كلما ازدادت قيمة \mathcal{K} .

٢- إذا كان $\mathcal{K} > 0$ ، فعندئذ يكون التوزيع **منبسطاً**، ويزداد انبساطاً كلما تناقصت قيمة \mathcal{K} .

٣- إذا كان $\mathcal{K} = 0$ ، فعندئذ يكون التوزيع **معتدلاً**، علماً أنَّ القيمة (0) أخذت كمقياس للاعتدال، وذلك على افتراض أنَّ قيمة \mathcal{K} للتوزيع الطبيعي المعياري (سنأتي على ذكره في الفصل السادس) تساوي الصفر وفقاً للعلاقة السابقة، والنظر إلى شكل التوزيع الطبيعي المعياري كنموذجٍ للتوزيعات معتدلة التفلطح كما ذكرنا ذلك في الفصل السابق (انظر الشكل السابق (١٤, ٢) لدالة الكثافة الاحتمالية للتوزيع الطبيعي المعياري من أجل قيم مختلفة لـ \mathcal{K}).

(١, ٣, ٥, ٢) **ملاحظات**

١- إذا كانت البيانات المُعطاة لعينة، فعندئذ يُفضّل استخدام الصيغة المُعدّلة الآتية لحساب مُعامل التفلطح:

$$\mathcal{K} := \frac{n^2(n+1) \cdot S^{(4)}}{(n-1)(n-2)(n-3) \cdot S^4} - 3 \frac{(n-1)^2}{(n-2) \cdot (n-3)} \quad [2,44-c]$$

وتناقش قيمة \mathcal{K} كما سبق.

٢- إنَّ العلاقة الأخيرة [2,44-c] تُستخدم في بعض البرامج الإحصائية (مثل: **Excel**, **SPSS**, **Minitab** و...) لحساب مُعامل

الالتواء من أجل بيانات العينات والمجتمعات على حدٍّ سواء، بمعنى أنَّه من أجل هذه الحالة تقوم بعض البرامج بالتعامل مع البيانات على أنَّها بيانات عينة.

(٢, ١, ٣, ٥, ٢) أمثلة

١- بالرجوع إلى المثال السابق (٤, ٢, ٥, ٢) حيث لدينا $S = 3.681$ ، وبحساب العزم المركزي من المرتبة الرابعة لتوزيع تلك البيانات نجده يساوي:

$$S^{(4)} = \frac{1}{31} \sum_{i=1}^{32} (x_i - \bar{x})^4 = \frac{12193.45}{31} = 393.3371$$

ومن ثم تكون قيمة مُعامل التفلطح لتوزيع البيانات المعطاة يساوي:

$$\mathcal{K} = \frac{S^{(4)}}{S^4} - 3 = \frac{393.3371}{183.596} - 3 = -0.8576$$

أو وفقاً للصيغة المعدلة لمعامل التفلطح:

$$\mathcal{K} = \frac{n^2 \cdot (n + 1)}{(n - 1) \cdot (n - 2) \cdot (n - 3)} \cdot \frac{S^{(4)}}{S^4} - 3 \frac{(n - 1)^2}{(n - 2) \cdot (n - 3)} = \frac{33792}{26970} \cdot \frac{393.3371}{183.596} - 3 \frac{1024}{870} = -0.71$$

وهي النتيجة ذاتها التي حصلنا عليها باستخدام برنامج **Minitab** (انظر التقرير السابق) التي تبين لنا أنَّ توزيع البيانات المعطاة منبسط.

(٢, ٦) الأعداد الخمسة والتمثيل الصندوقي للبيانات

Five Number and the Box plot

يفي الواقع تستخدم المخططات الصندوقية في معظم التحاليل الإحصائية الوصفية لأنها تعطي انطباعاً سريعاً للقارئ حول قيم الرُّبَيعَات الثلاثة وكذلك حول الالتواء الخاص بتوزيع البيانات.

(١, ٦, ٢) تعريف (الأعداد الخمسة لبيانات كمية خام)

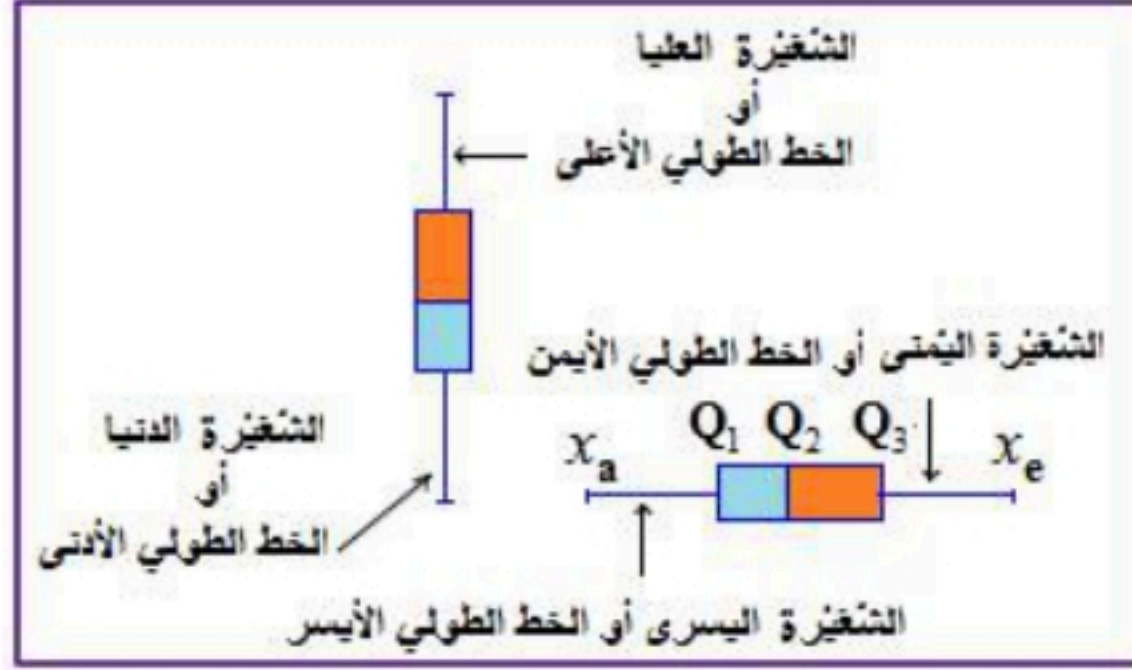
بفرض أنَّه لدينا x_1, x_2, \dots, x_n بيانات خام مُعطاة. عندئذ يُقصد بالأعداد الخمسة (في الإحصاء الوصفي) القيم الآتية:

- أصغر قيمة في البيانات x_s ،
- أكبر قيمة في البيانات x_ℓ ،
- قيم الرُّبَيعَات الثلاثة Q_1, Q_2 و Q_3 .

إنَّ هذه الأعداد الخمسة تساعدنا في وصف تركز البيانات، وانتشارها، وشكل توزيعها (من أجل التوزيعات المستمرة)، والجدول الآتي يوضِّح لنا ملخَّص العلاقات بين الأعداد الخمسة وشكل التوزيع للبيانات.

الجدول (١٠, ٢)

Left skewed ملتو نحو اليسار	$Q_2 - x_s > x_\ell - Q_2$	$Q_1 - x_s > x_\ell - Q_3$	$Q_2 - Q_1 > Q_3 - Q_2$
Symmetric متناظر	$Q_2 - x_s = x_\ell - Q_2$	$Q_1 - x_s = x_\ell - Q_3$	$Q_2 - Q_1 = Q_3 - Q_2$
Right skewed ملتو نحو اليمين	$Q_2 - x_s < x_\ell - Q_2$	$Q_1 - x_s < x_\ell - Q_3$	$Q_2 - Q_1 < Q_3 - Q_2$



شكل (٢, ١٥)

(٢, ٦, ٢) التمثيل الصندوقي لبيانات كمية خام

إنَّ العرض (أو التمثيل) الصندوقي Box plot لبيانات خام هو عرض رسومي للبيانات يقوم على أساس مُلخَّص الأعداد الخمسة السابقة، ويتكوَّن من صندوق وخطين طوليين يتوسطانه على طرفيه يمنة ويسرى يُدعيان "الشُعيرتان Whiskers". ويُقدَّم هذا العرض وفقاً لأحد الشكلين الآتيين:

تُعيَّن نهاية الشُعيرتان اليمنى X_e واليسرى X_a كما يلي:

١- إذا كانت مجموعة البيانات لا تحتوي قيماً متطرفة، فعندئذ يكون لدينا:

$$X_a = X_s \quad \& \quad X_e = X_\ell$$

٢- إذا كانت مجموعة البيانات تحتوي على قيم صغيرة متطرفة فقط، فعندئذ يكون $X_a = LF$. أي إنَّ نهاية الشُعيرة اليسرى

X_a توافق الحد الأعلى للقيم المتطرفة بصغرها، ومن ثمَّ تبلغ الشُعيرة اليسرى الطول الأعظمي لها. أمَّا X_e فيكون مساوياً لـ X_ℓ .

٣- إذا كانت مجموعة البيانات تحتوي على قيم كبيرة متطرفة فقط، فعندئذ يكون لدينا $X_e = HF$. أي إنَّ نهاية الشُعيرة اليمنى

X_e توافق الحد الأدنى للقيم المتطرفة بكبرها، ومن ثمَّ تبلغ الشُعيرة اليمنى الطول الأعظمي لها. أمَّا X_a فيكون مساوياً لـ X_s .

٤- إذا كانت مجموعة البيانات تحتوي على قيم صغيرة وكبيرة متطرفة، فعندئذ يكون لدينا $X_a = LF$ و $X_e = HF$.


وفي هذه الحالة تبلغ الشُعيرتان اليسرى واليمنى الطول الأعظمي لهما.

(٢, ٦, ١, ١) ملاحظات

١- عند تقديم الرسم الصندوقي يُشار إلى كل قيمة متطرفة بنجمة (*) أو نقطة (•).

٢- من أجل البيانات المستمرة (أي أنها بيانات مولدة من متغير مستمر) فإنه إذا كان توزيع البيانات متناظراً (أي متماثلاً حول الوسيط)،

فعندئذ الصندوق وخط الوسيط سوف يتمركزان بين نقاط نهايتي الشُعيرتين (انظر الشكل التوضيحي الآتي وهذه الخاصية تبقى صحيحة حتى من أجل البيانات المتقطعة - أي أنها بيانات مولدة من متغير متقطع -).




الشكل (٢, ١٦)

وأمَّا إذا كان توزيع البيانات ملتوياً فعندئذ:


أ- من أجل التوزيعات الملتوية نحو اليسار سوف ينزاح الصندوق لليمين باتجاه نهاية الشُعيرة اليمنى وأما خط الوسيط فيمكن

أن يأخذ أية وضعية داخل الصندوق وذلك بحسب قيمته بالنسبة إلى Q_1 و Q_3 (انظر الأمثلة التوضيحية الآتية).



الشكل (١٦, ٢. ب)

ب- من أجل التوزيعات الملتوية نحو اليمين سوف ينزاح الصندوق ليسار باتجاه نهاية الشُعيرة اليسرى وأما خط الوسيط فيمكن أن يأخذ أية وضعية داخل الصندوق وذلك بحسب قيمته بالنسبة إلى Q_1 و Q_3 (انظر الأشكال التوضيحية الآتية).



الشكل (١٦, ٢. ج)

(٢, ١, ٢, ٢) أمثلة


١- بالرجوع إلى المثال السابق (٤-٢-٥-٢) حيث وجدنا $S = 0.0575$. أي إن توزيع هذه البيانات ملتوياً بشكل طفيف جداً نحو اليمين. من جهة أخرى لدينا من مُعطيات المثال $x_s = 1$, $Q_1 = 4$, $\tilde{x} = Q_2 = 8$, $Q_3 = 10$ و $x_\ell = 15$ ، وبملاحظة أن:

$$LF = 4 - 1.5(10 - 4) = -5$$

فعندئذ القيم المتطرفة بصغرها هي تلك القيم التي تكون أصغر من -5 ، ومن ثم لا توجد قيم متطرفة بصغرها في البيانات المقدمة، وكذلك لدينا:


$$HF = 10 + 1.5(10 - 4) = 19$$

وهذا يعني أن القيم المتطرفة بكبرها هي تلك القيم التي تكون أكبر من 19 ، وبالتالي ليس لدينا أية قيم متطرفة بكبرها في البيانات المقدمة، ولذلك سيكون لدينا $x_a = x_s$ وكذلك $x_e = x_\ell$ ، ومن ثم يصبح التمثيل الصندوقي لتلك البيانات العرض الآتي:



الشكل (١٧, ٢. أ)

وباستخدام برنامج Minitab نحصل على التمثيل الصندوقي لهذه البيانات كما في العرض الآتي:



الشكل (١٧, ٢. ب)

٢- لتكن لدينا مجموعة البيانات الآتية:

8 4 7 6 9 1 5 9 3 17 5 -7

فعندئذ نجد أن $x_s = -7$ ، $x_\ell = 17$ ، $Q_1 = 3.5$ ، $\tilde{x} = Q_2 = 5$ و $Q_3 = 8.5$ ، وأما لتحديد القيم المتطرفة بصغرها التي تكون أصغر من نهاية الشعيرة اليسرى، فلدينا:


$$LF = 3.5 - 1.5(8.5 - 3.5) = -4$$

أي إن القيم المتطرفة بصغرها هي تلك القيم التي تكون أصغر من -4، ومن ثم لدينا قيمة متطرفة بصغرها واحدة هي $x_s = -7$.

أخيراً من أجل تحديد القيم المتطرفة بكبرها علينا حساب HF حيث لدينا:

$$HF = 8.5 + 1.5(8.5 - 3.5) = 16$$

أي إن القيم المتطرفة بكبرها هي تلك القيم التي تكون أكبر من 16، وبالتالي لدينا قيمة متطرفة بكبرها هي $x_\ell = 17$. هكذا تبلغان الشعيرتان اليمنى واليسرى الطول الأعظم لهما، حيث لدينا $x_a = LF = -4$ و $x_e = HF = 16$ ، ومن ثم يكون للتمثيل الصندوقي لتلك البيانات العرض الآتي:



الشكل (١٨، ٢)

هذا ما تيسر تقديمه من أجل الجزء النظري والتطبيقي لهذا الفصل

تمارين الفصل الثاني

- ١- إذا كانت x_1, x_2, \dots, x_n مع $1 \leq n$ مجموعة بيانات مُعطاة، فعندئذ:
- أ- هل يمكن لقيمة عددية x أن تكون مقياساً للنزعة المركزية لهذه المجموعة من البيانات علماً أنّها توافق x_ℓ (أكبر قيمة في البيانات) أو x_s (أصغر قيمة في البيانات)؟
- ب- بفرض أنّ \bar{x} هي قيمة المتوسط لهذه المجموعة من البيانات، فمن أجل أي قيمة لـ n تصبح $\bar{x} = x_\ell$ أو $\bar{x} = x_s$ ؟
- ج- من أجل أي قيمة لـ n تصبح قيمة الانحراف المعياري لهذه المجموعة من البيانات تساوي الصفر؟
- ٢- لتكن لدينا مجموعة البيانات الآتية التي تمثل الوزن لعينة مكونة من خمسين شخصاً بالغاً (مقدرة بالكيلو غرام):

75	92	74	73	62	80	76	66	79	60
77	84	77	71	81	75	84	65	61	82
91	67	81	69	58	64	83	75	68	62
69	64	74	63	84	64	73	92	77	64
98	65	86	76	69	66	74	68	61	99

والمطلوب ما يلي:

- أ- احسب المتوسط - الوسيط - المتوسط - المتوسط الهندسي - المتوسط التوافقي - المدى - الانحراف المتوسط - التباين - الانحراف المعياري - معامل التغير - معامل بيرسون للالتواء والتفلطح إذا علمت أنّ البيانات المُعطاة كانت:
- ب- احسب الدرجة المعيارية Z و T لكل من القيم الآتية:

99 81 74 65 58

- ج- احسب معامل الالتواء العزومي بصيغته المختلفة، ومن ثمّ قارن هذه القيم مع قيمة معامل الالتواء لبيرسون.
- د- ارسم التمثيل الصندوقي لهذه البيانات موضحاً عليها الأعداد الخمسة.
- هـ- تحت الفرض أنّ لجميع قيم البيانات المُعطاة النصيب نفسه في الاختيار ولا يؤثر بعضها في البعض الآخر لدى عملية السحب البيانات منها، فعندئذ قم بسحب عينات عشوائية من المجتمع السابق بحجم $n = 10$ و $n = 25$ و $n = 40$ ، ومن ثمّ احسب المقادير المطلوبة في البنود (أ) وحتى (هـ) السابقة، وبعد ذلك قارن بين النتائج المتقابلة. ماذا تستنتج؟

- ٣- ليكن لدينا مجموعة بيانات مقدّمة من خلال جدول توزيع تكراري له العرض الآتي:

رقم الفئة	الحدود الفعلية للفئة	مركز الفئة x_i	تكرار الفئة f_i	التكرار المتجمّع الصاعد للفئة F_i
1	50 → 55		5	
2	55 → 60			13
3			12	
4				40
5			17	
6				70
7	80 → 85		7	
Total	-----	-----	48	-----

والمطلوب ما يلي:

أ- أكمل بيانات هذا الجدول.

ب- احسب كلاً من المقادير الآتية في حالتها المجتمع والعينة:

المتوسط - الانحراف المتوسط - الانحراف المعياري - معامل التغير - معامل بيرسون للالتواء.

٤- إذا كان معدل العجز في ميزانية بلد ما خلال الأعوام 2008، 2009، 2010، 2011، 2012 و 2013 على الترتيب هو 3%، 2%، 9% و 6%، فعندئذ احسب معدل العجز في ميزانية هذا البلد خلال الأعوام الستة.

٥- لتكن لدينا البيانات الآتية التي تمثل عينة من نتائج نهاية الفصل لـ 60 طالباً في مقرر الإحصاء:


52	99	92	86	84	52	99	92	86	84
63	72	76	95	88	63	72	76	95	88
92	58	65	79	80	92	58	65	79	80
90	75	74	56	99	90	75	74	56	99
65	79	80	90	75	74	56	99	90	75
74	56	74	56	99	65	79	80	90	75

والمطلوب ما يلي:

أ- حساب المتوسط والانحراف المعياري ومن ثم معامل الالتواء العزومي ومعامل التفلطح لهذه البيانات.


ب- قدر عدد القيم التي تقع في الفترة $[\bar{x} - 2S, \bar{x} + 2S]$ ، ومن ثم بين إن كان هذا العدد يتوافق مع قاعدة تشيشفيف التجريبية أم لا؟

٦- لتكن لدينا مجموعات البيانات الموضحة في العروض الآتية:



والمطلوب حساب المتوسط، والوسيط، والمدى، والانحراف المعياري، ومعامل التغير لكل منها. ماذا تلاحظ؟ ومن ثم بين أيها أقل تبعثراً من الأخرى.

٧- ليكن لدينا المخطط الصندوقي الآتي لمجموعة بيانات:



والمطلوب ما يلي:

أ- تعيين الأعداد الخمسة على هذا المخطط، x_e ، x_a ، LF و HF.

ب- تحديد نوع التواء التوزيع مع ذكر الأسباب.

٨- لتكن لدينا مجموعة البيانات الآتية لعينة تمثل الوزن لمئة شخص بالغ (مقدرة بالكيلو غرام):

84	63	74	64	69	69	76	86	65	98
99	61	68	74	66	69	76	86	65	98
64	77	92	73	64	84	63	74	64	69
62	68	75	83	64	58	69	81	67	91
64	77	92	73	64	84	63	74	64	69
99	61	68	74	66	69	76	86	65	98
64	77	92	73	64	84	63	74	64	69
62	68	75	83	64	58	69	81	67	91
64	77	92	73	64	84	63	74	64	69
84	63	74	64	69	69	76	86	65	98

والمطلوب ما يلي:

أ- احسب الرُّبعيات الثلاثة لهذه البيانات.

ب- احسب المئينات P_{35} ، P_{50} و P_{65} لهذه البيانات.

ج- ارسم المخطط الصندوقي لهذه البيانات موضِّحاً عليه مواضع الأعداد الخمسة، ومن ثمَّ بيِّن نوع الالتواء لهذه البيانات.

هـ- عيِّن المئين الموافق لكل للقيم 65، 75 و 98.

٩- لتكن لدينا مجموعات لبيانات مقدَّمة من خلال المخططات الصندوقية الوضِّحة جانباً، والمطلوب ما يلي:

أ- عيِّن قيم الأعداد الخمسة الخاصة

بكل مخطط من المخططات (B1)

وحتى (B7).

ب- أيّ الأشكال السابقة يدلّ على

توزيع متناظر، ملتون نحو اليمين،

ملتون نحو اليسار.

هـ- أيّ الأشكال السابقة يشير إلى

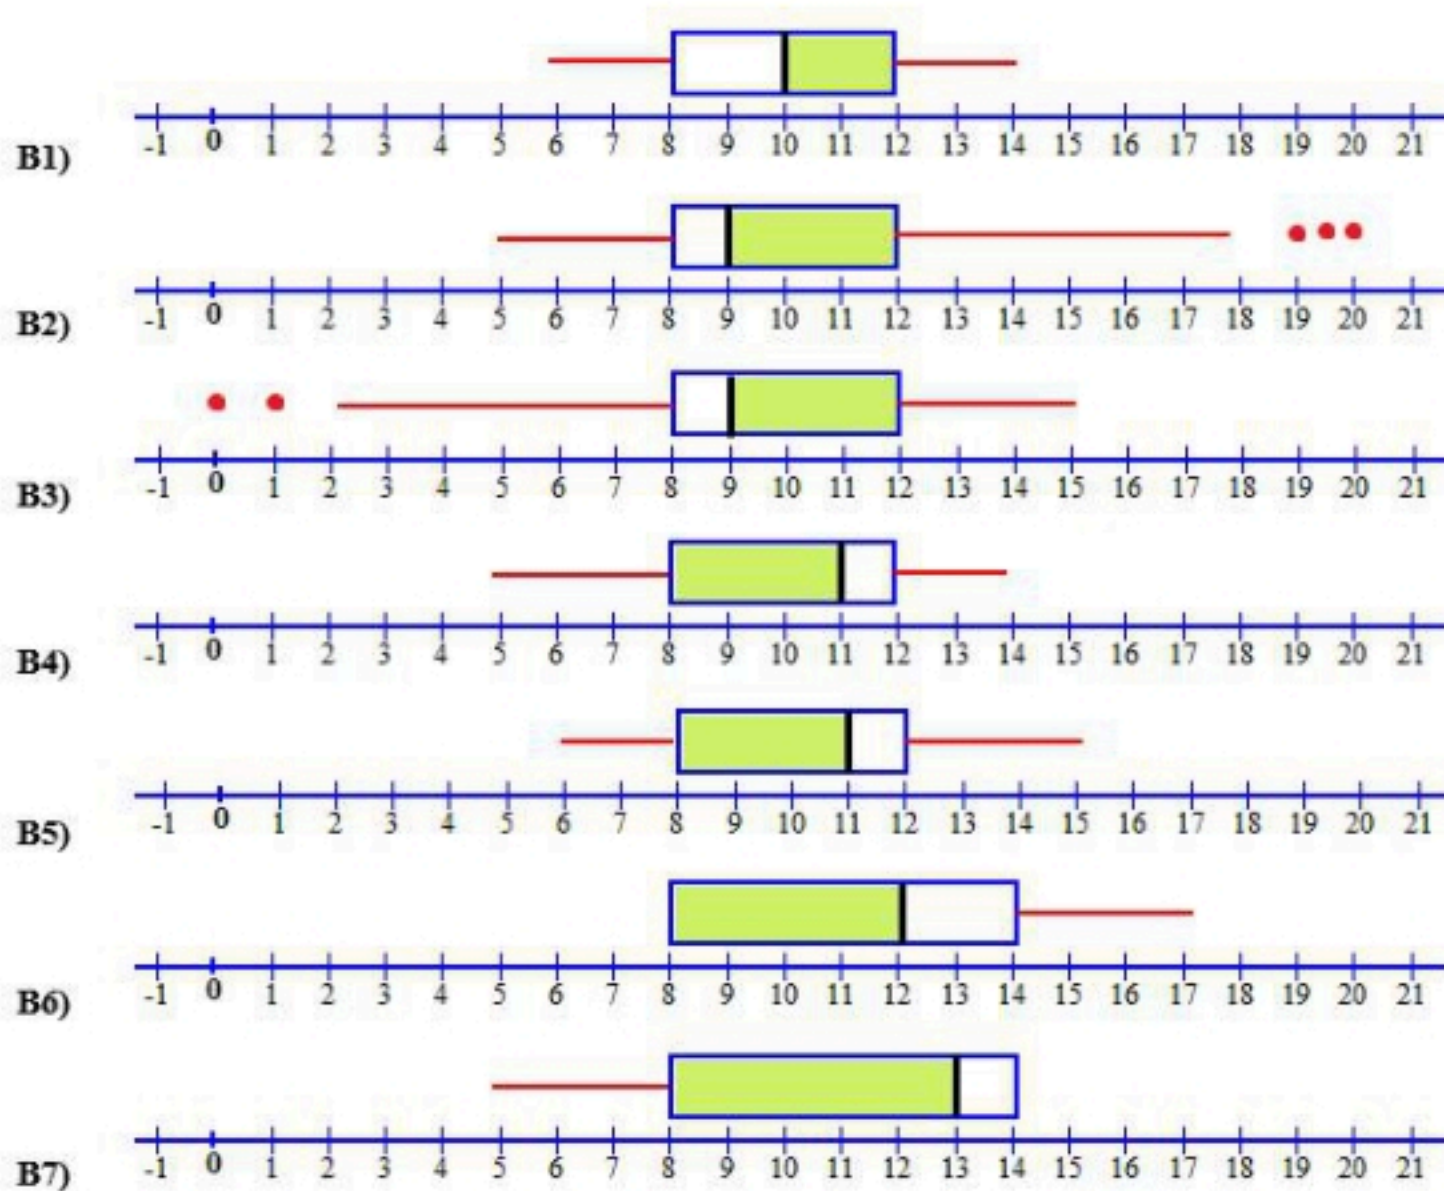
وجود قيم متطرفة بكبرها.

و- أيّ الأشكال السابقة يشير إلى

وجود قيم متطرفة بصغرها.

ز- قدِّم تفسيراً لغياب الشعيرات لدى

بعض المخططات.



الفصل الثالث

الارتباط وتحليل الانحدار CORRELATION AND REGRESSION ANALYSIS

(٣,١) الارتباط الخطي البسيط

Simple Linear Correlation

بعد أن قمنا في الفصلين السابقين بدراسة مفصلة بعض الشيء للبيانات، حيث لاحظنا أن هذه البيانات قد تكون قيماً لمتغير X يُعبر عن ظاهرة محددة A ، وأكثر من ذلك لاحظنا أنه قد تكون لدينا مجموعتين أو أكثر من البيانات التي قد يكون بعضها مختلف عن بعض، مثل الطول والوزن لأشخاص. هنا قد يتساءل المرء عن التأثير المتبادل بين ظاهرتين (أو متغيرين) أو أكثر، فعلى سبيل المثال: قد يتساءل المرء عن العلاقة التي تربط بين الطول والوزن لأشخاص من فئة عمرية معينة (فيكون لدينا متغيرين)، أو بين تركيز النيكوتين في الدم، وأمراض الرئة، وتصلب الشرايين لدى مجتمع من المدخنين (فيكون لدينا ثلاثة متغيرات)، أو مستوى الدخل واستهلاك بعض المواد الغذائية، وزيادة الوزن، واقتناء بعض أجهزة الرفاهية (فيكون لدينا أربعة متغيرات)، وهكذا دواليك ...

إن الأدوات المستخدمة لاستكشاف مثل هذه العلاقات واستخدامها في التقدير والتنبؤ تندرج تحت مفهوم الارتباط وتحليل الانحدار، ويمكن استخدام هذه الأدوات لمعرفة هل كانت النتيجة من متغير واحد Y تعتمد على قيم المتغيرات الأخرى X_1, X_2, \dots, X_k أم لا؟ وهذا ما تعنيه تبعية متغير لمتغيرات أخرى، حيث يُدعى Y متغير الاستجابة Response Variable (في الرياضيات يُدعى المتغير التابع Dependent Variable) وأما بقية المتغيرات X_1, X_2, \dots, X_k فإنها تُدعى متغيرات تفسيرية Explanatory Variables (في الرياضيات تُدعى متغيرات مستقلة Independent Variables).

(٣,١,١) نماذج من الارتباط

في الواقع إن مفهوم الارتباط يمكن استخدامه لوصف طبيعة العلاقة بين ظاهرتين أو أكثر، فلو قمنا برصد أكثر من ظاهرة كأن نقوم مثلاً برصد الوزن والطول لعناصر مجتمع من الأشخاص البالغين، فعندئذ يمكننا أن نمثل نتيجة الدراسة لكل عنصر من هذا المجتمع بمتجه ذي بُعد يساوي عدد الظواهر المستخدمة في الدراسة، وبعد ذلك يمكننا طرح السؤال الآتي:

هل ثمة علاقة ما تربط بين مركبات هذا المتجه، وإن كانت هناك علاقة ما تربط بين هذه المركبات، فما هي هذه العلاقة؟

قبل الإجابة على هذه التساؤلات سوف نتفق على استخدام كلمة متغير للدلالة على ظاهرة يمثلها هذا المتغير (كما قدمناه في الفصلين السابقين) الذي بدوره يقوم بتوليد البيانات الخاصة بهذه الظاهرة، فعلى سبيل المثال: لو أخذنا الظاهرة A هي ظاهرة الطول لكائنات عددها n ، فعندئذ المتغير X يلعب دور أداة القياس التي تقيس الطول وتولد البيانات x_1, x_2, \dots, x_n الممثلة لقيم الطول لهذه الكائنات. في هذه الحالة يُقال إن المتغير X راصد للظاهرة A وواصف للمجتمع الإحصائي الذي تنتمي إليه هذه البيانات.

الآن للإجابة على التساؤلات السابقة سنقوم بتجزئة هذه المسألة إلى نموذجين من المسائل هي:

١ - عندما تكون المسألة متعلقة برصد متغيرين X و Y فقط، فإنه في هذه الحالة يكون للبيانات شكل ثنائية مرتبة (x_i, y_i) من

أجل كل القيم الممكنة لـ i ، ويقال عن البيانات x_i و y_i من أجل كل القيم الممكنة لـ i إنها **بيانات متزاوجة**، وهنا يُبحث في اتجاهين رئيسيين أيضاً هما:

أ- إذا كانت العلاقة بين البيانات المتزاوجة x_i و y_i هي **علاقة خطية** من أجل كل القيم الممكنة لـ i .

ب- إذا كانت العلاقة بين البيانات المتزاوجة x_i و y_i هي **علاقة غير خطية** من أجل كل القيم الممكنة لـ i .

٢- عندما تكون المسألة متعلقة برصد أكثر من متغيرين (ولكن عدد متته من المتغيرات) X_1, X_2, \dots, X_k . في هذه الحالة تكون البيانات الناتجة عن الدراسة مُثَمَّلة بمتجهات $(x_{11}, x_{12}, \dots, x_{1k})$ ، $(x_{21}, x_{22}, \dots, x_{2k})$ ، \dots ، $(x_{n1}, x_{n2}, \dots, x_{nk})$ ، وهنا يُبحث في الحالتين الآتيتين أيضاً:

أ- إذا كانت العلاقة التي تربط بين متغير من هذا المتجه (X_1, X_2, \dots, X_k) مع بقية مركباته هي **علاقة خطية**.

ب- إذا كانت العلاقة التي تربط بين متغير من هذا المتجه (X_1, X_2, \dots, X_k) مع بقية مركباته هي **علاقة غير خطية**.

بالطبع سوف لن نقوم بدراسة كل هذه الفقرات من الحالات لأنها تحتاج إلى مجلدات لتغطيتها، ولكن سنركز على جوانب محدّدة من هذه الدراسات وبالقدر الذي يسمح لنا به هذا المؤلف مبتدئين ذلك بدراسة مبسطة للارتباط الخطي البسيط، وبعد ذلك الانتقال إلى مسائل متعلقة بالانحدار، وأخيراً نختم هذا الفصل بعرض موجز عن الارتباط المتعدد والجزئي. لكن قبل البدء في موضوع الارتباط الخطي البسيط سنقدّم بعض المفاهيم العامة والمتعلقة بالارتباط حيث يمكن لمن يودّ الاطلاع على المزيد الرجوع إلى المصادر المتخصصة في الارتباط وتحليل الانحدار والمذكور بعضها في فهرس المراجع في نهاية هذا الكتاب مثل [22] و [33] و [49] و [63].

لقد تحدثنا في الفصلين الأول والثاني عن طرائق إحصائية مُستخدمة في وصف ودراسة متغير واحد، حيث لاحظنا أنه يمكن لتلك الطرائق أن تُعطي تصوراً مقبولاً حول المتغير الذي هو قيد الدراسة، ولكنها لا تقدّم لنا تصوراً واضحاً ودقيقاً حول التأثير المتبادل بين متغيرين أو أكثر. بمعنى أنه لو طرح علينا السؤال الآتي:

هل التأثير المتبادل بين ظاهرتين ممثلتين بمتغيرين X و Y ، قوي أم ضعيف، طردي أم عكسي؟

للإجابة على هذا السؤال لا بدّ لنا من منهج علمي دقيق وواضح بعيداً عن التخمين الحدسي، ويقدم لنا مقداراً عددياً يعبر عن طبيعة التأثير المتبادل بين المتغيرات.

إنّ الارتباط (وفقاً لعلم الإحصاء) هو أحد المناهج العلمية الذي يتولّى هذه المهمة، ويهتم بتعيين مقدار عددي يعبر عن التأثير المتبادل بين عدد من المتغيرات (قد يعود إلى وجود علاقة سببية بينها- مثل العلاقة بين أطوال الأشخاص وأوزانهم-)، وهنا يمكننا أن نميز بين نماذج مختلفة من الارتباط كما يلي:

أولاً: من حيث التأثير والتأثر:

في هذا الإطار يوجد عدّة أنواع من الارتباط بحسب العلاقة التي تصفه، ومن هذه العلاقات ما يلي:

١- العلاقة الوحيدة الاتجاه Unidirectional Relation:

هذا النوع من الارتباط مبني على أنّ التغير في قيمه متغير يؤدي إلى تغير في قيم متغير آخر مرتبط به، وهذا التأثير غير عكوس. أي إن التغير في المتغير الأخير لا يؤثر في تغير المتغير الأول، ولذلك يدعى هذا النوع من الارتباط باسم **الارتباط السببي Causal Correlation**، ومن الأمثلة على ذلك:

أ- زيادة نسبة الأسمدة وفق معايير سليمة يؤدي إلى زيادة الإنتاج، إلا أنّ العكس ليس صحيحاً بالضرورة.

ب- كلما ازداد ارتفاعنا عن مستوى سطح البحر تنخفض درجة حرارة الهواء عموماً، إلا أنّ العكس ليس صحيحاً بالضرورة.

٢- علاقة السلسلة السببية Causal Chain Relation:

إنَّ هذا النوع من الارتباط يشابه النوع السابق من الارتباط، ولكنه يكون في سلسلة من نماذج الارتباط الوحيد الاتجاه (السببي)، فعلى سبيل المثال: هطول الأمطار يؤدي إلى تسرب مياه الأمطار إلى التربة، وهذا يزيد المحتوى المائي للتربة الذي بدوره يتسرب إلى مخازن المياه الجوفية، ونحصل نتيجة لذلك على زيادة في مخزون المياه الجوفية وبهذا تشكل لدينا سلسلة من العلاقات وحيدة الاتجاه، ولذلك يمكن إدراج هذا النوع من الارتباط تحت اسم **الارتباط السببي** أيضاً.

٣- العلاقة التبادلية Reciprocal Relation:

إنَّ هذا النوع من الارتباط مبني على التأثير المتبادل بين المتغيرات أو على رد الفعل، فكل تغير في متغير يؤدي إلى تغير في المتغير الآخر، فعلى سبيل المثال، لو كان لدينا دائرة كهربية مكونة من مقاومة ومنبع للتغذية (كما في الشكل التابع للمثال ٥ / من ١، ٢، ٤، ١، ١ / في الفصل الأول) فعندئذ تغير الجهد الكهربائي المطبق على طرفي الدارة سيؤدي إلى تغير شدة التيار المار في المقاومة، والعكس صحيح أيضاً، فإنَّ تغير شدة التيار المار في المقاومة سيرافقه تغيراً في الجهد الكهربائي المطبق على طرفي هذه المقاومة. لذلك أطلق على هذا النوع من الارتباط اسم **الارتباط التبادلي** Reciprocal Correlation.

٤- العلاقة الوهمية Spurious Relation:

في هذا النوع من الارتباط يبدو لنا ظاهرياً نوع من التأثير لمتغير على متغير آخر، ولكن هذا التأثير غير حقيقي، فعلى سبيل المثال: لو أخذنا تغير مستوى الوعي لدى طفل ومقارنة ذلك مع تغير طول يد هذا الطفل، فنجد أنَّ هناك علاقة طردية بينهما ولكنها ليست حقيقية، فلا تأثير لطول يد الطفل على وعيه ولا لوعيه على طول يده. لذلك أطلق على هذا النوع من الارتباط اسم **الارتباط الوهمي** Spurious Correlation.

ثانياً: من حيث عدد الظواهر

يمكننا هنا أن نصنف نوعين رئيسيين هما:

١- الارتباط البسيط Simple Correlation:

إنَّ **الارتباط البسيط** هو الارتباط الذي يهتم بالتأثير المتبادل بين متغيرين فقط، ومثال على ذلك تعيين مقدار التأثير المتبادل بين طول شخص ما ووزنه.

٢- الارتباط المتعدد Multiple Correlation:

إنَّ الارتباط المتعدد هو الارتباط الذي يهتم بالتأثير المتبادل بين عدة متغيرات (أكثر من متغيرين)، كأن نبحث في التأثير المتبادل بين ضغط الدم، ودرجة الحرارة، وعدد ضربات القلب، وكمية الأكسجين في الدم لمرضى السكر، فنكون في هذه الحالة أمام ما يُعرف باسم **الارتباط المتعدد**، وفي هذا النوع من الارتباط قد يلجأ الباحث إلى دراسة التأثير المتبادل بين متغيرين فقط مع تجاهل (أو تثبيت) التأثير المتبادل بين بقية المتغيرات، وفي هذه الحالة نكون أمام ما يُعرف باسم **الارتباط الجزئي** Partial Correlation.

الآن لنفترض أنَّه لدينا (x_1, y_1) ، (x_2, y_2) ، و... (x_n, y_n) بيانات مقدَّمة على شكل ثنائيات مرتبة (ندعوها بيانات متزاوجة). إنَّ طبيعة هذه البيانات لا تهمنا بشيء، فقد تكون طبيعة البيانات x_1, x_2, \dots, x_n مختلفة عن طبيعة البيانات y_1, y_2, \dots, y_n ، ولكن المهم هنا أن يكون البيان y_i هو البيان المقابل لـ x_i من أجل كل القيم الممكنة لـ i ، فعلى سبيل المثال لو أخذنا البيانات الآتية التي تمثل نتائج الاختبار التحريري (مقدَّرة بالدرجات) والمقابلة (مقدَّمة بالتقديرات: ممتاز - جيد جداً - جيد - وسط - ضعيف) في مقرر الإحصاء لعشرة من الطلاب كما في الجدول الآتي:

الجدول (١، ٣)

الطالب	A	B	C	D	E	F	G	H
الامتحان التحريري X	8	8	5	9	7	7	9	10
امتحان المقابلة Y	جيد	جيد جداً	وسط	جيد	جيد	وسط	جيد	جيد جداً

فلاحظ أن البيانات x_1, x_2, \dots, x_n هي بيانات كمية في حين أن البيانات y_1, y_2, \dots, y_n هي بيانات نوعية. أكثر من ذلك قد تكون هذه البيانات ناتجة عن تطبيق دراسة متعلقة بظاهرتين A و B على عناصر عينة أو مجتمع كما في المثال السابق حيث لدينا الظاهرة A هي نتائج الاختبار التحريري والظاهرة B هي نتائج اختبار المقابلة. لا بل أكثر من ذلك فقد تكون البيانات x_1, x_2, \dots, x_n هي لحظات زمنية متتالية في حين أن y_1, y_2, \dots, y_n هي قيم لظاهرة B متعلقة بتطور هذه اللحظات الزمنية المتتالية على الترتيب، فعلى سبيل المثال لو أخذنا البيانات المقدمة في الجدول الآتي (تمثل إنتاج القمح مقدراً بالـ 100,000 طن في بلد ما من العام 2002 وحتى 2010):

الجدول (٢، ٣)

السنة	2002	2003	2004	2005	2006	2007	2008	2009	2010
الكمية	8	12	9	15	11	9	7	9	13

ومن الممكن أن تكون البيانات مولدة بطرائق أخرى مختلفة عن الحالات المقدمة سابقاً أيضاً، والمهم هنا (وكما ذكرنا سابقاً) أن تكون البيانات المعطاة متزاوجة.

الآن، ولدراسة الارتباط بين متغيرين X و Y ، سنميز بين الحالتين الآتيتين:

١- الحالة التي تكون فيها العلاقة التي تربط بين المتغيرين X و Y هي علاقة خطية فقط، أي من الشكل:

$$Y = f(X) = a + bX$$

علماً أن a و b قيمتان ثابتتان يطلب تعيينهما، فعندئذ يتحدث المرء عن **الارتباط الخطي البسيط**.

٢- الحالة التي تكون فيها العلاقة التي تربط بين المتغيرين X و Y هي علاقة غير خطية، كأن تكون العلاقة بينهما (على سبيل المثال

لا الحصر) من أحد الأشكال الآتية:

$$Y = f(X) = a \sin bX \quad \& \quad Y = f(X) = a \cdot b^X$$

$$Y = f(X) = a_0 + a_1 X + a_2 X^2 + \dots + a_m X^m \quad ; m \geq 2$$

علماً أن a, b, c ، وكذلك $a_0, a_1, a_2, \dots, a_n$ قيم ثابتة يطلب تعيينهما، فعندئذ يتحدث المرء عن **الارتباط غير الخطي** Non Linear Correlation.

(١، ١، ٣) ملاحظة

تجدر الملاحظة هنا إلى أن درجة الارتباط التي نحصل عليها تعتمد على نوع العلاقة المفترضة ومدى صحة هذا الافتراض، وهذه حقيقة يجب مراعاتها عند تفسير النتائج التي نحصل عليها، فلو افترضنا أن العلاقة بين متغيرين هي علاقة خطية، وتبين لنا أن درجة الارتباط (أي قوة الارتباط، أي: قوية، أم متوسطة، أم ضعيفة) منخفضة جداً فإن ذلك لا يعني أكثر من احتمال عدم وجود علاقة خطية بين المتغيرين، ولا يعني عدم وجود ارتباط بينهما، إذ إنه من الممكن أن يكون الارتباط بينهما له شكل علاقة غير خطية. كما أن وجود درجة ارتباط قوية بينهما قد لا يعني وجود علاقة أصلاً بين الظاهرتين مثلما هو الحال لدى الارتباط الوهمي.

الآن وقبل تقديم بعض المعايير العددية التي تقيس لنا درجة الارتباط بين متغيرين X و Y سنقوم بشرح لمفهوم **لوحة الانتشار** التي تعدّ من الوسائط المهمة في هذه الدراسات. إن الغاية من هذه اللوحة أخذ انطباع أولي عن طبيعة التأثير المتبادل بين المتغيرين التفسيري X والاستجابة Y .

Scatter Plot (٣, ١, ٢) لوحة الانتشار

لتكن لدينا $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ بيانات معطاة، فعندئذ لوحة الانتشار لهذه البيانات هي التمثيل النقطي للبيانات (أي تمثيل البيانات بنقاط) على المستوي الإحداثي XOY ، ويؤخذ عادة في الإحداثيات المتعامدة، أي إن x_1, x_2, \dots, x_n وكذلك y_1, y_2, \dots, y_n هي مساقط النقاط الممثلة لهذه البيانات على المحور OY و OX على الترتيب (انظر الشكل الجانبي)، ولإعطاء المزيد من التوضيح سنقدم الأمثلة الآتية.

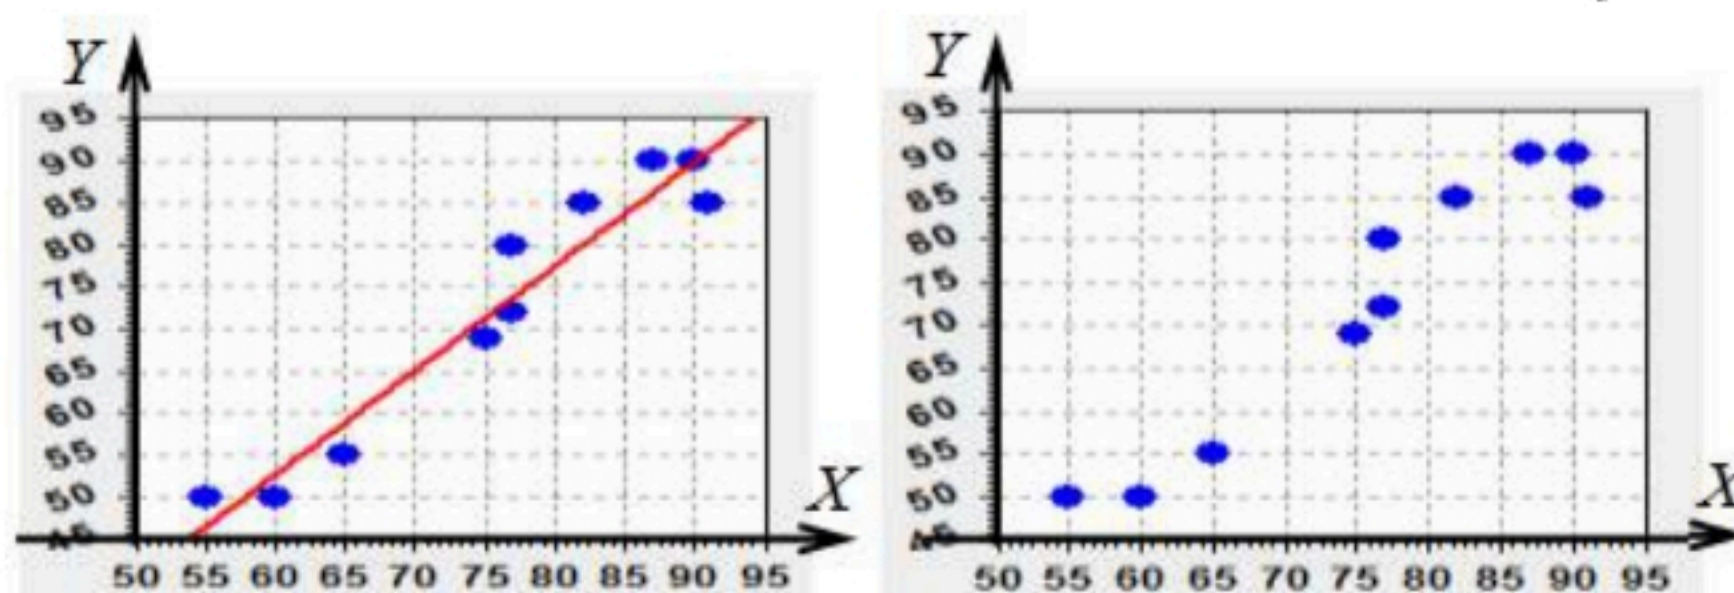
أمثلة: (٣, ١, ٢, ١)

١ - لنفترض أننا نرغب في الكشف عن درجة الارتباط بين الطول والوزن لعشرة أشخاص بالغين، ومن أجل هذه الغاية قمنا بقياس الطول والوزن لعشرة أشخاص بالغين تم اختيارهم عشوائياً، فحصلنا على البيانات $(x_1, y_1), (x_2, y_2), \dots, (x_{10}, y_{10})$ المقدمة من خلال الجدول الآتي:

الجدول (٣, ٣)

i	X الوزن	Y الطول	i	X الوزن	Y الطول
1	75	69	6	60	50
2	82	85	7	55	50
3	65	55	8	87	90
4	90	90	9	91	85
5	77	80	10	77	72

علماً أن الوزن X مقدر بالكيلو غرام والطول Y مقدر بالبوصة Inch. عندئذ نجد أن لوحة الانتشار لهذه البيانات لها العرض الموضح بالشكل (٣, ١, أ) الآتي.

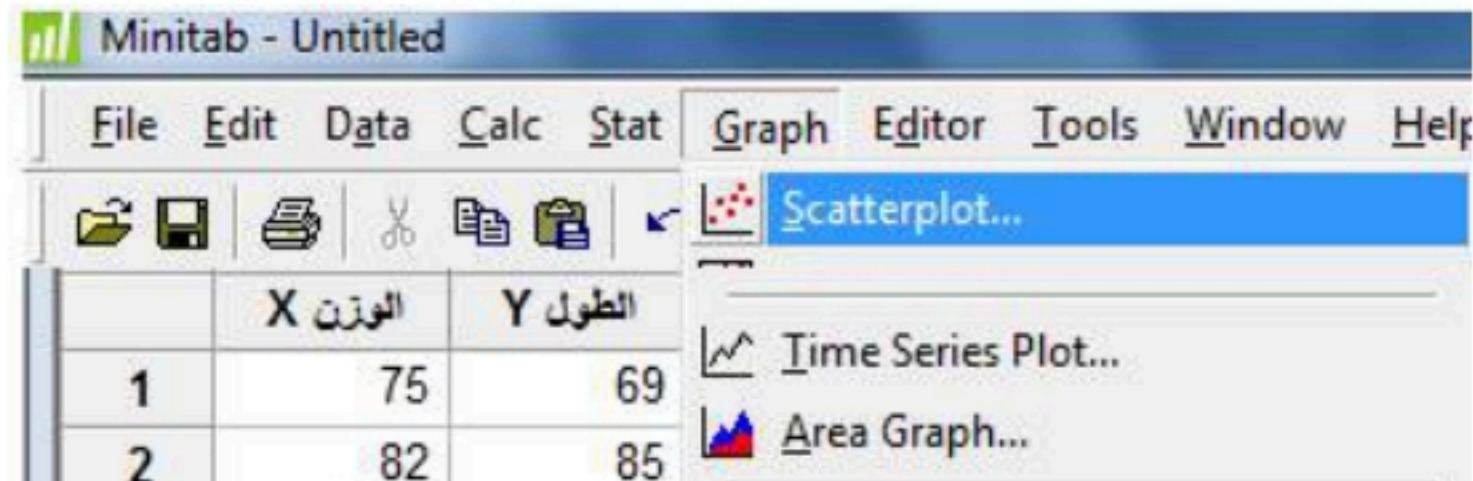


الشكل (٣, ١, ب)

الشكل (٣, ١, أ)

حيث نلاحظ أن هذه النقاط تظهر منحى صاعداً، بمعنى أنه كلما ازدادت قيمة مركبة أدى ذلك إلى زيادة قيمة المركبة الأخرى، وهذا السلوك في الارتباط يدعى الارتباط الإيجابي (أو الطردي) للبيانات. أما بخصوص قوة التأثير المتبادل (أي قوة الارتباط وسوف نوضح لاحقاً معنى قوة الارتباط) بين الطول والوزن، فإن الشكل السابق يظهر لنا درجة عالية من التأثير المتبادل بين الطول والوزن وذلك بسبب وقوع معظم البيانات بالقرب من مستقيم ممثل لمنحى هذه البيانات (سنأتي على شرح كيفية تعيين هذا المستقيم لاحقاً في تحليل الانحدار الخطي من هذا الفصل)، انظر الشكل السابق (٣, ١, ب).

يمكننا الحصول على لوحة الانتشار (أو لوحة الانتشار مع الخط المستقيم المار بين البيانات) باستخدام برنامج Minitab من خلال الفقرة Graph ثم Scatterplot وبعد ذلك اختيار المربع Simple أو المربع With Regression، وأخيراً OK، والصور الآتية توضح ذلك:



ومن ثمَّ




فنحصل على الشكلين السابقين (أ. ٣, ١) و (ب. ٣, ١).

٢- أخضعت مجموعة مكونة من 10 رجال بدينين من ذوي وزن 140 كغ لدورة رياضية ونظام غذائي موحد من أجل تخفيض أوزانهم بحيث يمارس كل منهم فترة زمنية ما يومياً حسب استطاعته ولمدة 45 يوماً، وبعد ذلك قيس الوزن لكل منهم، ومن ثمَّ دُون إلى جانب عدد الساعات التي مارسها، فكانت النتائج كما في الجدول الآتي:


الجدول (٤, ٣)

الرجل	X عدد الساعات التي مارسها خلال 45 يوماً	Y الوزن عند نهاية الدورة
1	30	131
2	45	125
3	56	122
4	42	128
5	90	103
6	33	131
7	48	120
8	35	127
9	70	110
10	82	108

ف نجد أنَّ لوحة الانتشار للبيانات المعطاة لها العرض الموضح بالشكل (أ. ٣, ٢) الآتي:



الشكل (٢, ٣. ب)




الشكل (٢, ٣. أ)

وكذلك نلاحظ أن النقاط الممثلة للبيانات تُظهر منحنى هابطاً بحيث إنه كلما ازدادت قيمة مُركبة أدى ذلك إلى نقصان في قيمة المُركبة الأخرى، وهذا السلوك في الارتباط يُدعى **الارتباط السلبي (أو العكسي)** للبيانات، وأما بخصوص درجة الارتباط فإن الشكل يظهر لنا درجة عالية من التأثير المتبادل بين عدد ساعات الرياضة ونقصان الوزن، وذلك بسبب وقوع معظم البيانات بالقرب من المستقيم الممثل لمنحنى هذه البيانات (انظر الشكل (٣, ٣. ب)).

٣- تقدّم ستة عشر طالباً للاختبار النهائي في مقرري الرياضيات واللغة العربية، فكانت لهم النتائج كما في الجدول الآتي (مقدّرة من 50 درجة).

الجدول (٥, ٣)

الطالب	درجة اختبار الرياضيات X	درجة اختبار اللغة العربية Y	الطالب	درجة اختبار الرياضيات X	درجة اختبار اللغة العربية Y
1	45	32	9	28	13
2	48	17	10	35	35
3	30	25	11	39	22
4	50	50	12	42	50
5	43	44	13	32	50
6	37	15	14	38	42
7	34	44	15	31	41
8	44	36	16	29	50



الشكل (٣, ٣)

عندئذ نجد أن لوحة الانتشار لهذه البيانات لها العرض الموضح بالشكل (٣, ٣)، وكذلك نلاحظ أن النقاط الممثلة للبيانات المعطاة تُظهر توزعاً على شكل غيمة يصعب تحديد اتجاهها (**المنحنى غير واضح تماماً**)، بمعنى أنه من خلال النظر بالعين المجردة يصعب تحديد طبيعة التأثير المتبادل بين المتغيرين X و Y من حيث الإيجابية أو السلبية.

إذاً، وكما لاحظنا، فإننا بحاجة لمقياس عددي يوضح لنا طبيعة الارتباط أهو إيجابي أم سلبي؟ أم هو قوي أم ضعيف؟ إن المقاييس العددية التي تقوم بهذه المهمة تُدعى **معاملات الارتباط** Correlation Coefficients، وسنرمز له بـ r من أجل العينات وبـ ρ من أجل المجتمعات، وقد تُرفق هذه الرموز بدليل لتمييز نوع المقياس المستخدم.

(٢, ٢, ١, ٣) ملاحظات

قبل القيام بتقديم بعض المفاهيم المتعلقة بالارتباط والانحدار، فإننا سنتفق على الآتي تجنباً للتقديم المطول، ومن أجل توضيح المفاهيم التي سنقدمها:

١- عندما نذكر أنه لدينا $(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$ بيانات مجتمع خاضع لمتغيرين X و Y ، فإننا نقصد بذلك:
أ- إما أن تكون عناصر مجتمع إحصائي منته حجمه N أخضعت لدراسة متجه (X, Y) (مكوناته المتغيرين X و Y) وحصلنا نتيجة لذلك على هذه البيانات المتزاوجة، ومثال على ذلك تنفيذ مسح شامل لمجتمع مرضى السكري في مدينة ما بحيث يُحدد لكل مريض نسبة السكر والشحوم الثلاثية في دمه، فعندئذ نحصل على بيانات متزاوجة من النموذج الموصوف آنفاً.

ب- أو أن تكون البيانات x_1, x_2, \dots, x_N هي قيم ناتجة عن إخضاع عناصر مجتمع إحصائي منته حجمه N لدراسة المتغير X ، في حين أن البيانات y_1, y_2, \dots, y_N هي قيم ناتجة عن إخضاع عناصر مجتمع إحصائي آخر منته حجمه N لدراسة المتغير Y ، وبحيث تكون البيانات x_1, x_2, \dots, x_N و y_1, y_2, \dots, y_N البيانات المتزاوجة المذكورة آنفاً، وكمثال على ذلك لو رصدنا قيم البورصة لإحدى الشركات منذ اشتراكها في البورصة وحتى وقت بدء هذه الدراسة وعلى فترات زمنية منفصلة ومتتالية (ليس بالضرورة أن تكون الفترات الزمنية متساوية)، فعندئذ نحصل على بيانات متزاوجة من النموذج الموصوف آنفاً. حيث تلعب البيانات x_1, x_2, \dots, x_N دور اللحظات الزمنية التي رصدت عندها قيم البورصة y_1, y_2, \dots, y_N .

٢- عندما نذكر أنه لدينا $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ بيانات عينة خاضعة لمتغيرين X و Y ، فإننا نقصد بذلك:
أ- إما أن تكون عناصر عينة حجمها n مسحوبة من مجتمع إحصائي أخضعت لدراسة هذين المتغيرين X و Y وحصلنا نتيجة لذلك على هذه البيانات المتزاوجة المذكورة آنفاً.

ب- أو أن تكون البيانات x_1, x_2, \dots, x_n هي قيم ناتجة عن إخضاع عناصر عينة حجمها n مسحوبة من مجتمع إحصائي لدراسة المتغير X ، وكذلك البيانات y_1, y_2, \dots, y_n هي قيم ناتجة عن إخضاع عناصر عينة حجمها n مسحوبة من مجتمع إحصائي آخر لدراسة المتغير Y ، وبحيث تكون البيانات x_1, x_2, \dots, x_n وكذلك y_1, y_2, \dots, y_n هي البيانات المتزاوجة المذكورة آنفاً.
فيما يلي نقدم أحد التعاريف المهمة في إطار الارتباط وتحليل الانحدار، ويُعرف باسم **التغاير** Covariance (أو **تمام التباين**).

(٣, ١, ٣) تعريف (التغاير لمجموعتي بيانات Covariance of two Data Sets)

من أجل تعريف التغاير لمجموعتين من البيانات سنناقش الحالتين الآتيتين:

أولاً: من أجل البيانات الخام:

أ- لنفترض أن $(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$ بيانات مجتمع خاضع لمتغيرين X و Y ، فعندئذ يُعرف **التغاير** بين بيانات المتغيرين X و Y (سنرمز له بـ $\sigma_{X,Y}$) بالعلاقة الآتية:

$$\sigma_{X,Y} := \frac{1}{N} \sum_{i=1}^N (x_i - \mu_X) \cdot (y_i - \mu_Y) \quad [3,1-a]$$

علماً أن μ_X و μ_Y هو المتوسط لبيانات X و Y على الترتيب.

ب- لنفترض أن $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ بيانات عينة خاضعة لمتغيرين X و Y ، فعندئذ يُعرف **التغاير** بين بيانات X و Y (سنرمز له بـ $S_{X,Y}$) بوساطة العلاقة الآتية:

$$S_{X,Y} := \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y}) \quad [3,1-b]$$

علماً أن \bar{x} و \bar{y} هو المتوسط لبيانات X و Y على الترتيب.

ثانياً: إذا كانت البيانات **المُعطاة مُجمَّعة** في جدول تكراري مشترك:

إذا كان لدينا مجموعتي بيانات إحداها ناتجة عن متغير X والأخرى ناتجة عن متغير Y ، ومُعطاة من خلال جدول تكراري واحد ذي فئات تظهر فيه التكرارات للبيانات المشتركة بين مجموعتي البيانات، ويدعى هذا الجدول بـ **الجدول التكراري المشترك Joint Frequency Table** لمجموعتي البيانات.

الآن لنفترض أنه لدينا مجموعتين من البيانات إحداها ناتجة عن متغير X والأخرى ناتجة عن متغير Y ، وصُيِّت هذه البيانات في جدول تكراري مشترك كما يلي:

الجدول (٦، ٣)

		فئات X				Total
		$\alpha_1 - \alpha_2$	$\alpha_2 - \alpha_3$	$\alpha_k - \alpha_{k+1}$	
فئات Y	$\beta_1 - \beta_2$	f_{11}	f_{21}	f_{k1}	$\sum_{i=1}^k f_{i1}$
	$\beta_2 - \beta_3$	f_{12}	f_{22}	f_{k2}	$\sum_{i=1}^k f_{i2}$
	\vdots
	$\beta_\ell - \beta_{\ell+1}$	$f_{1\ell}$	$f_{2\ell}$	$f_{k\ell}$	$\sum_{i=1}^k f_{i\ell}$
Total		$\sum_{j=1}^{\ell} f_{1j}$	$\sum_{j=1}^{\ell} f_{2j}$	$\sum_{j=1}^{\ell} f_{kj}$	$\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij}$

علماً أن f_{ij} هو التكرار المشترك بين الفئة (α_i, α_{i+1}) و (β_j, β_{j+1}) ، فعندئذ:

١- إذا كانت هذه البيانات لمجتمعين إحصائيين متتهين حجم كل منها N ، فعندئذ يُحسب التباين بين بيانات X و Y والممثلة بالجدول السابق (٤، ٣) كما يلي:

$$\sigma_{X,Y} = \frac{\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij} (x_i - \mu_X)(y_j - \mu_Y)}{\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij}} \quad [3,2-a]$$

علماً أن x_i هو مركز الفئة $\alpha_i \rightarrow \alpha_{i+1}$ من أجل كل $i \in N_k$ ، وبالمثل y_j هو مركز الفئة $\beta_j \rightarrow \beta_{j+1}$ من أجل كل $j \in N_\ell$ ، وأخيراً μ_X و μ_Y هو المتوسط لبيانات X و Y على الترتيب، ويُحسبان كما يلي:

$$\mu_X = \frac{\sum_{i=1}^k \left(x_i \cdot \sum_{j=1}^{\ell} f_{ij} \right)}{\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij}} \quad [3,2-b]$$

$$\mu_Y = \frac{\sum_{j=1}^{\ell} \left(y_j \cdot \sum_{i=1}^k f_{ij} \right)}{\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij}} \quad [3,2-c]$$

٢- إذا كانت هذه البيانات لعيتين حجم كل منهما n ، فعندئذ يُحسب التغير بين بيانات X و Y والممثلة بالجدول السابق (٦، ٣) كما يلي:

$$S_{X,Y} = \frac{\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij} (x_i - \bar{X})(y_j - \bar{Y})}{\left(\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij} \right) - 1} \quad [3,3-a]$$

علماً أن \bar{X} و \bar{Y} هو المتوسط لبيانات X و Y على الترتيب، ويُحسبان كما يلي:


$$\bar{X} = \frac{\sum_{i=1}^k \left(x_i \cdot \sum_{j=1}^{\ell} f_{ij} \right)}{\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij}} \quad [3,3-b]$$

$$\bar{Y} = \frac{\sum_{j=1}^{\ell} \left(y_j \cdot \sum_{i=1}^k f_{ij} \right)}{\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij}} \quad [3,3-c]$$

فلاحظ أن التغير المُعطى بالعلاقات [3,2-a] و [3,3-a] هو التغير الذي قدّم سابقاً من أجل البيانات الخام نفسه، ولكن عدلت صيغته لكي توافق الجداول التكرارية المشتركة.


(١، ٣، ١، ٣) ملاحظات

١- إذا وجدنا أن قيمة التغير موجبة تماماً، فإن ذلك يعني أن منحى البيانات سيكون صاعداً، وأما إذا كانت قيمة التغير سالبة تماماً فإن ذلك يعني أن منحى البيانات سيكون هابطاً، وأخيراً إذا كانت قيمة التغير تساوي الصفر فإن ذلك يعني إحدى الحالتين الآتيتين:



أ) يكون توزع البيانات في لوحة الانتشار ليس له منحى واضح (أو على شكل غيمة عديمة الاتجاه)، فلو كانت (1,1)، (1,3)، (3,1)، و (3,3) بيانات عينة، فعندئذ نلاحظ أنه لا يمكن تحديد منحى لهذه البيانات، وبحساب التغير بين قيم X و Y نجد:

$$S_{X,Y} := \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{X})(y_i - \bar{Y}) = \frac{0}{3} = 0$$



ب) يكون منحى البيانات موازياً للمحور الأفقي (أو موازياً للمحور الرأسى)، فلو كانت (1,1)، (1,3)، (3,1)، (2,3)، و (3,3) بيانات عينة، فعندئذ نلاحظ أن منحى هذه البيانات أفقي، وبحساب التغير بين قيم X و Y نجد:

$$S_{X,Y} := \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{X})(y_i - \bar{Y}) = \frac{0}{5} = 0$$

٢- إذا أخذنا الحالة الخاصة $X = Y$ ، فعندئذ سينتج لدينا $S_{X,X} = S_X^2$ وهو تباين العينة الناتجة عن تطبيق المتغير X ، وكذلك $\sigma_{X,X} = \sigma_X^2$ هو تباين المجتمع الناتج عن تطبيق المتغير X أيضاً.

٣- المصفوفة التي لها العرض الآتي:

$$\begin{pmatrix} S_{X,X} & S_{X,Y} \\ S_{Y,X} & S_{Y,Y} \end{pmatrix} \quad \text{or} \quad \begin{pmatrix} \sigma_{X,X} & \sigma_{X,Y} \\ \sigma_{Y,X} & \sigma_{Y,Y} \end{pmatrix}$$

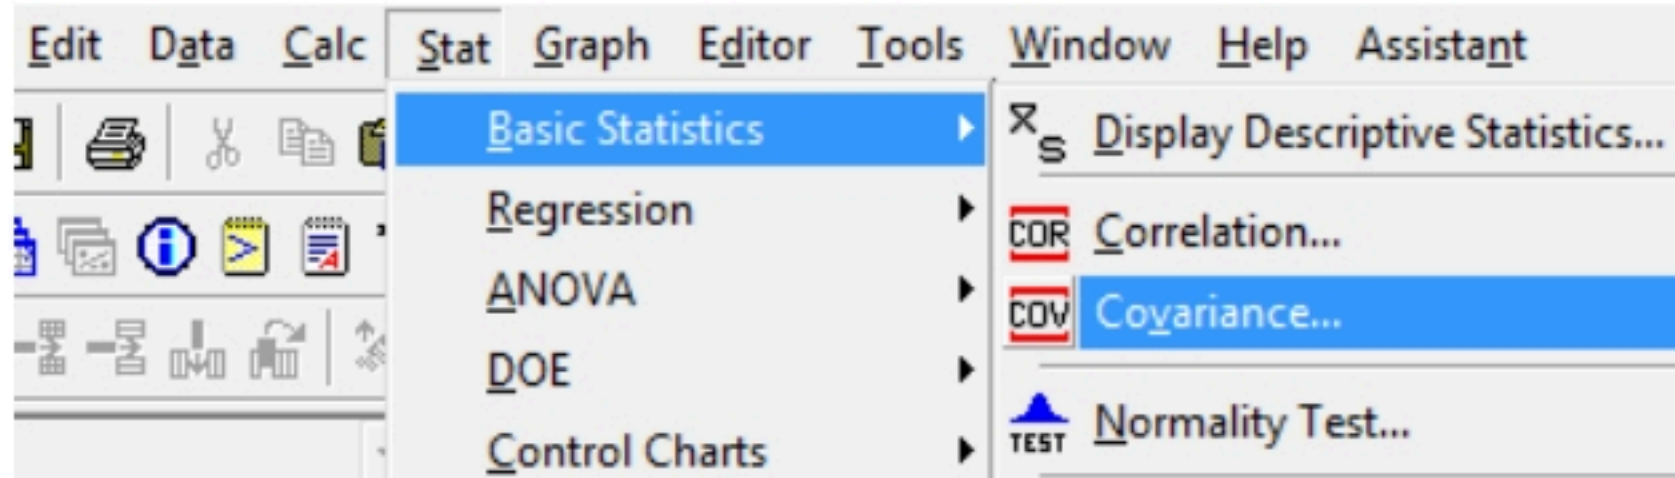
تُدعى **مصفوفة التباين** Covariance Matrix لبيانات X و Y ، وهي مصفوفة متناظرة لأن $S_{X,Y} = S_{Y,X}$ وكذلك $\sigma_{X,Y} = \sigma_{Y,X}$.

٤- عندما يُطلب من برنامج إحصائي (مثل Minitab أو SPSS) حساب التباين للبيانات المقدمة فإنه يتعامل معها على أنها بيانات عينة فقط، فعلى سبيل التوضيح لو رجعنا إلى الأمثلة (٣-١-٢-١) فإننا نجد ما يلي:

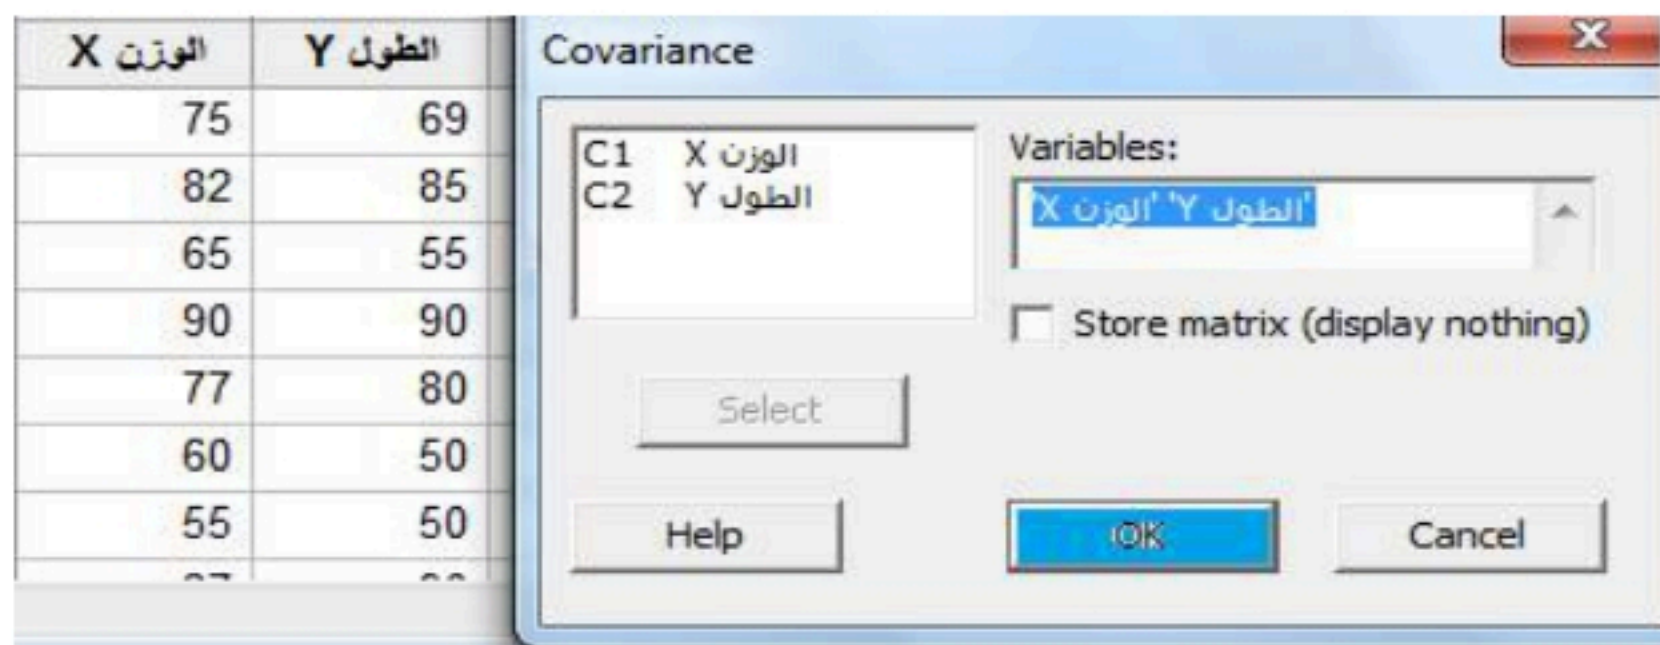
أ- من أجل بيانات المثال / ١ / من (٣-١-٢-١) لدينا $\bar{x} = 75.9$ وكذلك $\bar{y} = 72.6$ ، ومن ثم تكون قيمة تباين البيانات X و Y تساوي:

$$S_{X,Y} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y}) = \frac{1735.6}{9} = 192.844$$

وهكذا نجد $0 < S_{X,Y}$ ، وهذا يعني أن مَنحى البيانات يجب أن يكون صاعداً (وهذا موافق لما لاحظناه سابقاً على لوحة الانتشار في الشكل (٣، ١))، ولدى استخدام برنامج Minitab لحساب قيم التباين بين بيانات X و Y من خلال عرض مصفوفة التباين لهما وذلك وفقاً للخطوات الموضحة في الأشكال الآتية:



ومن ثم



فنحصل على التقرير الآتي لمصفوفة التباين للبيانات المعطاة:

Covariances: X الوزن; Y الطول

	X الوزن	Y الطول
X الوزن	155.433	192.844
Y الطول	192.844	256.933

ب- من أجل بيانات المثال / ٢ / من (٣-١-٢-١) لدينا $\bar{x} = 53.1$ وكذلك $\bar{y} = 120.5$ ، ومن ثم تكون قيمة التغير بين البيانات X و Y تساوي:


$$S_{X,Y} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y}) = \frac{-1868.5}{9} = -207.611$$

وهكذا نجد $S_{X,Y} > 0$ ، وهذا يعني أن منحنى البيانات يجب أن يكون هابطاً (وهو موافق لما لاحظناه سابقاً على لوحة الانتشار في الشكل (٣، ٢)).

ج- من أجل بيانات المثال / ٣ / من (٣-١-٢-١) لدينا $\bar{x} = 37.813$ وكذلك $\bar{y} = 35.375$ ، ومن ثم سيكون التغير بين بيانات X و Y يساوي:

$$S_{X,Y} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y}) = \frac{95.125}{15} = 6.342$$

وهكذا نجد $S_{X,Y} < 0$ ، وهذا يعني أن منحنى البيانات يجب أن يكون صاعداً رغم صعوبة تحديد المنحنى بالعين المجردة من خلال لوحة الانتشار، ولكن ميل Slope المنحنى لهذه البيانات سيكون صغيراً (انظر الشكل الآتي، وأما تعيين معادلة هذا المنحنى فسوف نأتي عليها في الفقرة القادمة من هذه الفصل).



الشكل (٣، ٦)

مثال (٣، ١، ٣، ٢)

لتكن لدينا البيانات الآتية الناتجة عن إخضاع مجموعة مكونة من 87 طالباً لاختبارين، أحدهما X يمثل مقرر الرياضيات العامة (الدرجة القصوى 80)، والآخر Y يمثل مقرر الإحصاء (الدرجة القصوى 30).

(41,12)	(58,20)	(58,21)	(46,16)	(54,19)	(42,14)	(64,23)	(60,21)	(29,10)	(41,13)	(74,25)
(63,22)	(71,25)	(79,29)	(69,24)	(40,12)	(55,19)	(69,24)	(52,19)	(55,20)	(71,25)	(45,15)
(49,17)	(74,25)	(31,11)	(53,19)	(38,12)	(49,17)	(36,11)	(49,17)	(40,12)	(46,16)	(61,22)
(48,17)	(43,14)	(53,19)	(41,13)	(50,18)	(75,27)	(49,17)	(51,18)	(78,27)	(50,18)	(34,11)
(44,15)	(20,10)	(75,26)	(57,20)	(59,21)	(43,14)	(46,16)	(75,27)	(32,11)	(64,23)	(53,19)
(50,18)	(69,23)	(23,10)	(67,23)	(47,17)	(79,29)	(79,28)	(61,21)	(52,19)	(64,23)	(39,12)
(62,22)	(71,25)	(33,11)	(51,18)	(31,10)	(44,15)	(46,16)	(43,15)	(74,26)	(47,16)	(46,16)
(44,15)	(69,24)	(59,21)	(54,19)	(51,18)	(42,14)	(48,17)	(33,11)	(63,23)	(60,21)	

فلو قمنا بصب هذه البيانات في جدول توزيع تكراري مشترك تكون فيه سعة الفئات للبيانات X تساوي 10، وسعة الفئات للبيانات Y تساوي 4 (على سبيل المثال). فإننا سنحصل على جدول تكراري مشترك لهذه البيانات له العرض الآتي:

الشكل (٣, ٧)

فئات Y	فئات X						Total
	20→30	30→40	40→50	50→60	60→70	70→80	
10 → 14	3	6	7	-	1	-	17
14 → 18	-	2	11	9	-	-	22
18 → 22	-	1	7	10	5	-	23
22 → 26	-	-	1	1	9	6	17
26 → 30	-	-	1	-	-	7	8
Total	3	9	27	20	15	13	87

وبحساب المقادير المطلوبة لحساب التغير بين بيانات X و Y نجد أن:

$$S_{X,Y} = \frac{\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij} (x_i - \bar{x}) (y_j - \bar{y})}{\left(\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij} \right) - 1} = \frac{4462.51}{86} = 51.89$$

الذي يظهر لنا أن منحى البيانات إيجابي، وأما بشأن قوة التأثير المتبادل بين المقيرين فإنه بحاجة لدراسة أخرى سنأتي على ذكرها لاحقاً. لقد اقترح أخذ التغير بين البيانات كمقياس لمدى الارتباط بين هذه البيانات، ولكن لوحظ أنه من الممكن أن تكون وحدة القياس لكل من القيم x_i و y_i مختلفت بعضها عن بعض (مثل: الطول بـ المتر، والوزن بـ الكيلوغرام)، ومن ثم يصبح استخدام التغير لقياس التأثير المتبادل بين البيانات عديم الجدوى، ولهذا قدمت بعض المقاييس التي تُعطي دلالات أفضل حول التأثير المتبادل بين البيانات ولا تحتوي على التناقضات التي وجدت في التغير، ومن هذه المقاييس نقدّم المقاييس الآتية.

(٤, ١, ٣) معامل بيرسون للارتباط Person's Coefficient of Correlation:

لقد لاحظ بيرسون أن قيمة التغير بين البيانات مرتبطة بوحدة القياس، وعلاوة على ذلك لاحظ أن اختلاف قيمة التشتت لكل من مجموعتي البيانات قد يؤثر في قيمة هذا المقياس أيضاً، ولذلك قام بتقسيم قيمة التغير على حاصل ضرب الانحراف المعياري لكل من مجموعتي البيانات، فحصل نتيجة لذلك على مقدار عددي مجرد من وحدة القياس للبيانات ولا يتأثر بتشتت البيانات. لذلك قدّم هذا المقياس لاستخدامه في قياس قوة الارتباط الخطي بين مجموعتين من البيانات. أما لحساب معامل بيرسون للارتباط الخطي (وسنرمز له بـ ρ_P من أجل المجتمع وبـ r_P من أجل العينة) فإننا سنناقش الحالتين الآتيتين:

أولاً: إذا كانت البيانات المعطاة خام:

١- بفرض أن $(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$ بيانات مجتمع خاضع لمتغيرين X و Y ، وأن للبيانات x_1, x_2, \dots, x_N و y_1, y_2, \dots, y_N متوسط وانحراف معياري μ_X و σ_X على الترتيب، وكذلك للبيانات y_1, y_2, \dots, y_N متوسط وانحراف معياري μ_Y و σ_Y على الترتيب، فعندئذ يُحسب معامل بيرسون للارتباط الخطي لهذه البيانات ρ_P بالعلاقة الآتية:

$$\rho_P := \begin{cases} \frac{\sigma_{X,Y}}{\sigma_X \cdot \sigma_Y} & \text{for } \sigma_X, \sigma_Y > 0 \\ 0 & \text{elseswhere} \end{cases} \quad [3,4-a]$$

ومن أجل σ_X و $\sigma_Y > 0$ يمكن استخدام إحدى العلاقات المكافئة الآتية لحسابه أيضاً:

$$\rho_P = \frac{1}{N} \sum_{i=1}^N \frac{(x_i - \mu_X)}{\sigma_X} \cdot \frac{(y_i - \mu_Y)}{\sigma_Y} \quad [3,4-b]$$

$$\rho_P = \frac{\sum_{i=1}^N x_i y_i - N \mu_X \mu_Y}{\sqrt{\sum_{i=1}^N x_i^2 - N \mu_X^2} \cdot \sqrt{\sum_{i=1}^N y_i^2 - N \mu_Y^2}} \quad [3,4-c]$$

$$\rho_P = \frac{N \left(\sum_{i=1}^N x_i y_i \right) - \left(\sum_{i=1}^N x_i \right) \cdot \left(\sum_{i=1}^N y_i \right)}{\sqrt{N \left(\sum_{i=1}^N x_i^2 \right) - \left(\sum_{i=1}^N x_i \right)^2} \cdot \sqrt{N \left(\sum_{i=1}^N y_i^2 \right) - \left(\sum_{i=1}^N y_i \right)^2}} \quad [3,4-d]$$

٢- بفرض أن $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ بيانات عينة أخضعت لمتغيرين X و Y ، وأن للبيانات x_1, x_2, \dots, x_n ومتوسط وانحراف معياري \bar{x} و S_X على الترتيب، وكذلك للبيانات y_1, y_2, \dots, y_n متوسط وانحراف معياري \bar{y} و S_Y على الترتيب، فعندئذ يُحسب معامل بيرسون للارتباط الخطي بين هذه البيانات بالعلاقة الآتية:

$$\mathbf{r}_P := \begin{cases} \frac{S_{X,Y}}{S_X \cdot S_Y} & \text{for } S_X, S_Y > 0 \\ 0 & \text{elsewhere} \end{cases} \quad [3,5-a]$$

ومن أجل S_X و $S_Y > 0$ يمكن استخدام إحدى العلاقات المكافئة الآتية لحسابه:

$$\mathbf{r}_P = \frac{1}{n-1} \sum_{i=1}^n \frac{(x_i - \bar{x})}{S_X} \cdot \frac{(y_i - \bar{y})}{S_Y} \quad [3,5-b]$$

$$\mathbf{r}_P = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sqrt{\sum_{i=1}^n x_i^2 - n \bar{x}^2} \cdot \sqrt{\sum_{i=1}^n y_i^2 - n \bar{y}^2}} \quad [3,5-c]$$

$$\mathbf{r}_P = \frac{n \cdot \left(\sum_{i=1}^n x_i y_i \right) - \left(\sum_{i=1}^n x_i \right) \cdot \left(\sum_{i=1}^n y_i \right)}{\sqrt{n \cdot \left(\sum_{i=1}^n x_i^2 \right) - \left(\sum_{i=1}^n x_i \right)^2} \cdot \sqrt{n \cdot \left(\sum_{i=1}^n y_i^2 \right) - \left(\sum_{i=1}^n y_i \right)^2}} \quad [3,5-d]$$

ثانياً: إذا كانت البيانات المعطاة مجمعة في جدول تكراري مشترك:

بفرض أنه لدينا بيانات معطاة من خلال جدول تكراري مشترك كما في الجدول (٦، ٣)، فعندئذ:

١- إذا كانت هذه البيانات **لمجتمع** حجمه منته ويساوي N وأخضع لمتغيرين X و Y ، ومن ثم صبت نتائجها في ذلك الجدول، وكان الانحراف المعياري لبيانات X و Y هو σ_X و σ_Y على الترتيب مع $\sigma_X, \sigma_Y > 0$ ، فعندئذ يُحسب معامل بيرسون للارتباط الخطي لبيانات ذلك الجدول من خلال العلاقة الآتية:

$$\rho_p = \frac{\sigma_{X,Y}}{\sigma_X \cdot \sigma_Y} = \frac{\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij} (x_i - \mu_X) (y_j - \mu_Y)}{\sigma_X \cdot \sigma_Y \cdot \sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij}} \quad [3,6-a]$$

علماً أنَّ x_i هو مركز الفئة $\alpha_i \rightarrow \alpha_{i+1}$ من أجل كل $i \in N_k$ ، وبالمثل y_j هو مركز الفئة $\beta_j \rightarrow \beta_{j+1}$ من أجل كل $j \in N_{\ell}$ ، وأما f_{ij} فهو التكرار المشترك بين الفئتين (α_i, α_{i+1}) و (β_j, β_{j+1}) .

أما إذا كان $\sigma_X = 0$ أو $\sigma_Y = 0$ ("أو" هنا لا تفيد الحصر) فإننا سنضع $\rho_p = 0$. علماً أنَّ σ_X^2 و σ_Y^2 يحسبان كما يلي:

$$\sigma_X^2 = \frac{1}{\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij}} \sum_{i=1}^k \left((x_i - \bar{x})^2 \cdot \sum_{j=1}^{\ell} f_{ij} \right) \quad [3,6-b]$$

$$\sigma_Y^2 = \frac{1}{\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij}} \sum_{j=1}^{\ell} \left((y_j - \bar{y})^2 \cdot \sum_{i=1}^k f_{ij} \right) \quad [3,6-c]$$

٢- إذا كانت هذه البيانات **لعينة** حجمها n أخضعت لمتغيرين X و Y ، ومن ثم صُبت نتائجها في الجدول (٦، ٣)، وبفرض أنَّ الانحراف المعياري لبيانات X و Y هو S_X و S_Y على الترتيب مع $S_X > 0$ و $S_Y > 0$ ، فعندئذ يُحسب معامل بيرسون للارتباط الخطي لبيانات ذلك الجدول من خلال العلاقة الآتية:

$$r_p = \frac{S_{X,Y}}{S_X S_Y} = \frac{\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij} (x_i - \bar{x}) (y_j - \bar{y})}{S_X S_Y \left(\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij} - 1 \right)} \quad [3,7-a]$$

وأما إذا كان $S_X = 0$ أو $S_Y = 0$ فإننا نضع $r_p = 0$. علماً أنَّ S_X^2 و S_Y^2 يُحسبان كما يلي:

$$S_X^2 = \frac{1}{\left(\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij} \right) - 1} \sum_{i=1}^k \left((x_i - \bar{x})^2 \cdot \sum_{j=1}^{\ell} f_{ij} \right) \quad [3,7-b]$$

$$S_Y^2 = \frac{1}{\left(\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij} \right) - 1} \sum_{j=1}^{\ell} \left((y_j - \bar{y})^2 \cdot \sum_{i=1}^k f_{ij} \right) \quad [3,7-c]$$

وهنا نودّ أن نشير إلى الأمور الآتية:

أ- يُستخدم هذا المقياس من أجل البيانات الكمية فقط، ويُعدّ من المقاييس الجيدة للارتباط الخطي، وجودته تكمن في أنّه يستخدم جميع قيم بيانات المتغيرين X و Y في الحساب.

ب- إنَّ الصيغ المستخدمة لحساب معامل الارتباط الخطي لبيرسون هي نفسها لجميع العلاقات السابقة، ولكن عدّل عليها لكي تتوافق مع المعطيات المتوفرة من البيانات.

ج) عندما يُطلب من برنامج إحصائي (مثل Minitab أو SPSS) حساب معامل بيرسون للارتباط الخطي للبيانات المقدّمة فإنّه يتعامل معها على أنّها بيانات عينة فقط.

من المعلوم أن البيانات التي نحصل عليها نتيجة دراسة إحصائية على مجتمع أو عينة قد تكون نوعية أو كمية أو مختلطة (بمعنى أن إحداها كمية والأخرى نوعية) في حال البيانات المتزاوجة، وهذا يعني أنه إذا كانت البيانات الواجب دراسة الارتباط بينهما هي بيانات نوعية أو مختلطة فإن معامل بيرسون الذي قدم قبل قليل لم يعد صالحاً للاستخدام، ومن ثم يجب تقديم مقياس آخر لإيجاد معامل الارتباط بحيث يعطي دلالة جيدة لمدى التأثير المتبادل بين مجموعتي البيانات. إن الفقرة الآتية تقدم لنا مقياساً مقبولاً لتعيين نوع ودرجة الارتباط لبيانات نوعية، أو كمية، أو مختلطة.

(٣, ١, ٥) معامل سبيرمان لارتباط الرتب Spearman's Rank Correlation Coefficient

لنفترض أنه لدينا عينة مسحوبة من مجتمع إحصائي، ونتائجها ثنائيات (أي كل عنصر أخضع لدراسة متغيرين أو ظاهرتين X و Y)، وأن بيانات هذه العينة هي بيانات كمية، نوعية أو مختلطة، ولنقم ببناء جدول يدون في صفه العلوي عناصر العينة أو رموزها (انظر الجدول الآتي وتابع الخطوات القادمة عليه)، ومن ثم نقوم بتنفيذ الخطوات الآتية:

الشكل (٣, ٨)

العنصر	e_1	e_2	e_{n-1}	e_n
قيم المتغير X	x_1	x_2	x_{n-1}	x_n
الرتب الأولية α_i	α_1	α_2	α_{n-1}	α_n
الرتب النهائية α_i^*	α_1^*	α_2^*	α_{n-1}^*	α_n^*
قيم المتغير Y	y_1	y_2	y_{n-1}	y_n
الرتب الأولية β_i	β_1	β_2	β_{n-1}	β_n
الرتب النهائية β_i^*	β_1^*	β_2^*	β_{n-1}^*	β_n^*
$d_i = \alpha_i^* - \beta_i^*$	d_1	d_2	d_{n-1}	d_n
d_i^2	d_1^2	d_2^2	d_{n-1}^2	d_n^2

١- إعطاء كل بيان x_i و y_i من هذه البيانات رقماً ندعوه **الرتبة الأولية Initial Rank** وسنرمز له بـ α_i و β_i لكل $i \in N_n$ على الترتيب، وبحيث يكون لهذه الرتب الأولية صفة تصاعدية (أو تنازلية) ولكل من مجموعتي البيانات X و Y بأن واحد، بمعنى أنه لا يجوز أن نعطي إحدى مجموعتي البيانات رتباً تصاعدياً والأخرى رتباً تنازلية.

٢- تعيين المتوسط لرتب البيانات المتماثلة (أو القيم المتساوية في حالة البيانات الكمية)، ومن ثم إعطاء كل واحدة من هذه البيانات المتماثلة (أو القيم المتساوية) قيمة هذا المتوسط التي تدعى **الرتبة النهائية Final Rank**، وسنرمز لها بـ α_i^* و β_i^* لكل $i \in N_n$.

٣- حساب الفروقات بين الرتب النهائية المتقابلة α_i^* و β_i^* ، وسنرمز لهذه الفروق بـ d_i لكل $i \in N_n$ ، أي إن:

$$d_i = \alpha_i^* - \beta_i^* \quad [3,8]$$

٤- نقوم بتربيع قيم الفروقات d_i فنحصل على d_i^2 لكل $i \in N_n$.

٥- نضع ما يلي:

$$r_s := 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)} \quad [3,9]$$

إنَّ قيمة r_s التي اشتقها سبيرمان كحالة خاصة من علاقة بيرسون العزومية للارتباط لدى استخدام رتب القيم أو القراءات بدلاً من القيم نفسها تُدعى **معامل سبيرمان لارتباط الرتب** (أو **معامل الارتباط الرتبي لـ سبيرمان**)، وهذه القيمة تقيس قوة الارتباط الخطي بين ظاهرتين. إنَّ العلاقة [3,9] ترجع إلى الإحصائي البريطاني **سبيرمان** (Charles Edward Spearman 1863-1945)، كما يطلق عليها اسم **معامل سبيرمان-رو للارتباط** Spearman-Rho Correlation Coefficient أيضاً.

(١, ٥, ١, ٣) ملاحظات


١- إنَّ معامل الارتباط الخطي لبيانات عينة يُعدُّ مقدراً لمعامل الارتباط الخطي لبيانات المجتمع، ولكن عند استخدام البرامج الإحصائية لحساب معامل الارتباط الخطي لبيانات متغيرين X و Y ، فإنَّ معظم هذه البرامج تتعامل مع البيانات على أنَّها بيانات عينة فقط، ولذلك عندما نكتب r فإنَّنا سنقصّد بذلك أيَّ معامل من معاملات الارتباط الخطي سواء كانت البيانات لعينات أو لمجتمعات.

٢- إنَّ قيمة r تنتمي إلى الفترة $[-1, +1]$ دوماً، وإذا كان:


أ - لدينا $0 < r$ فعندئذ يُقال إنَّ الارتباط بين المتغيرين X و Y **إيجابي** (أو **طردي**).

ب- لدينا $0 > r$ فإنَّه يُقال إنَّ الارتباط بين المتغيرين X و Y **سلبي** (أو **عكسي**).

ج- لدينا $r = \pm 1$ فعندئذ يُقال عن الارتباط بين المتغيرين X و Y إنَّه خطي تام، وفي هذه الحالة تكون جميع النقاط الممثّلة للملاحظات (x_i, y_i) مع $N_n \ni i$ تقع على خط مستقيم واحد. لكن يجب التنبيه هنا إلى أنَّ العكس ليس صحيحاً بالضرورة، فلو نظرنا إلى مجموعة البيانات الموضّحة من خلال الشكل الآتي (٣, ٨) لوجدنا أنَّ جميع النقاط الممثّلة لها تقع على مستقيم واحد، ومن ثمَّ ترتبط مع بعضها ارتباطاً خطياً تاماً، إلّا أنَّه بسبب انعدام الانحراف المعياري $S_Y = 0$ (أيَّ $r = 0$).



الشكل (٣, ٨)



الشكل (٣, ٩)

د - لدينا $r = 0$ فعندئذ لا يُقال إنَّه لا يوجد ارتباط بين الظاهرتين، بل نكون أمام إحدى الحالات الثلاث الآتية:

د-١- توزع البيانات على لوحة انتشار له شكل غيمة عديمة الاتجاه، أو في تجمعات جزئية متناثرة تشكّل بمجملها مشهداً يصعب تحديد اتجاهه، ومن ثمَّ منحنى البيانات سيكون غير واضح، ومن الأمثلة على ذلك الشكل (٣, ٤) حيث لدينا $S_{X,Y} = 0$ ، ومن ثمَّ $r = 0$ ، وكذلك بعض العروض التوضيحية الأخرى تجدها في الشكل الآتي (٣, ٩).

د-٢- منحى البيانات يوازي أحد محوري لوحة الانتشار، ومن الأمثلة على ذلك الشكل (٥، ٣) حيث لدينا $S_{X,Y} = 0$ ومن ثم $r = 0$ ، وكذلك بعض العروض التوضيحية الأخرى تجدها في الشكل الآتي (٩، ٣).


د-٣- توزع البيانات على لوحة انتشار له شكل بيان علاقة غير خطية بين المتغيرين X و Y ، ونماذج توضيحية على ذلك تجدها في الشكل الآتي (٩، ٣).

٣- لتقييم قوة وضعف الارتباط الخطي بين بيانات المتغيرين X و Y ، فإنه يقال إن هذا الارتباط: الشكل (٩، ٣)


قيمة معامل الارتباط	$0.86 < r \leq 1$	$0.70 < r \leq 0.86$	$0.50 < r \leq 0.70$	$0.30 < r \leq 0.50$	$0 \leq r \leq 0.30$
الحكم على الارتباط	قوي جداً	قوي	متوسط القوة	ضعيف	ضعيف جداً

وهذه المناقشة تبقى سارية المفعول على كافة مقاييس الارتباط الخطي للبيانات سواء كانت لعينات أو لمجتمعات.


٤- من الممكن أن يكون لدينا مجموعات بيانات (على شكل ثنائيات) ذات توزيعات مختلف بعضها عن بعض الآخر، ومع ذلك تمتلك قيمة واحدة لمعامل الارتباط الخطي، فلو أمعنا النظر في سلسلة العروض البيانية الآتية التي تشتهر باسم رباعية إنسكومب Anscombe's Quartet، وكان قد قدمها الإحصائي الإنكليزي إنسكومب (1918-2001) Francis John Anscombe عام (1973) في جامعة كامبريدج.




الشكل (١٠، ٣.ب)



الشكل (١٠، ٣.أ)



شكل (١٠، ٣.د)



الشكل (١٠، ٣.ج)

وهذه العروض تذكرنا بأنه في كثير من الأحيان يكون من المهم جداً النظر إلى توزع النقاط الممثلة للبيانات على لوحة الانتشار قبل تحليلها، حيث يمكن للقيم المتطرفة وأنماط أخرى من التوزع غير الخطي للبيانات أن يكون لها تأثير كبير في دراسة البيانات وعلى النتائج المتمخضة عنها، ففي الأشكال السابقة لدينا أربع مجموعات من البيانات المتزاوجة لها الخصائص الآتية نفسها:

المتوسط $(\bar{X}, \bar{Y}) = (7, 5)$ ، التباين $(S_X^2, S_Y^2) = (4, 2)$ ، معامل ارتباط $r = 0.816$ وخط الانحدار $\hat{Y} = 3 + 0.5X$ (سنأتي على ذكر هذا المفهوم لاحقاً).

لكن كما هو ملاحظ من لوحات الانتشار الأربع أن توزيع المتغيرات مختلفة جداً من مجموعة إلى أخرى. لابل اثنتين منهما (اللوحه في الأسفل (٨، ٣) و (٨، ٣د) تخضع لعلاقة غير خطية، وهذه الأمثلة تظهر لنا بجلاء أن معامل الارتباط لا يشير بالضبط إلى أن هناك علاقة دالة خطية بين X و Y ، وإنما يشير إلى أي مدى يمكن لهذه العلاقة أن تقترب من علاقة خطية فقط.

٥- لقد لاحظنا أن قيمة معامل الارتباط الخطي r تشير إلى قوة وجود علاقة خطية بين متغيرين X و Y ، ولكن هذه القيمة لا تميز العلاقة بينهما تماماً في الحالة العامة، وعلى وجه الخصوص إذا كان التوقع الشرطي لـ Y بالنسبة إلى X ليست خطية في X (للاطلاع على مفهوم التوقع الشرطي للمتغيرات العشوائية يمكن الرجوع إلى نهاية الفصل السابع).

٦- ربما يكون الارتباط من أكثر المفاهيم تعاطياً في الإحصاء. حيث نلاحظ أن كثيراً من الناس يستخدمون كلمة ارتباط على أنها تعني أي نوع من الارتباط بين متغيرين X و Y ، ولكن في الحقيقة له معنى تقني صارم للغاية، إذ إنه يعني القوة لعلاقة خطية واضحة بين متغيرين X و Y على مجال $I_1 \times I_2 \subseteq \mathbb{R}^2$.

(٢, ١, ٥, ٣) أمثلة

١- بالرجوع إلى الأمثلة (١, ٢, ١, ٣) نجد ما يلي:

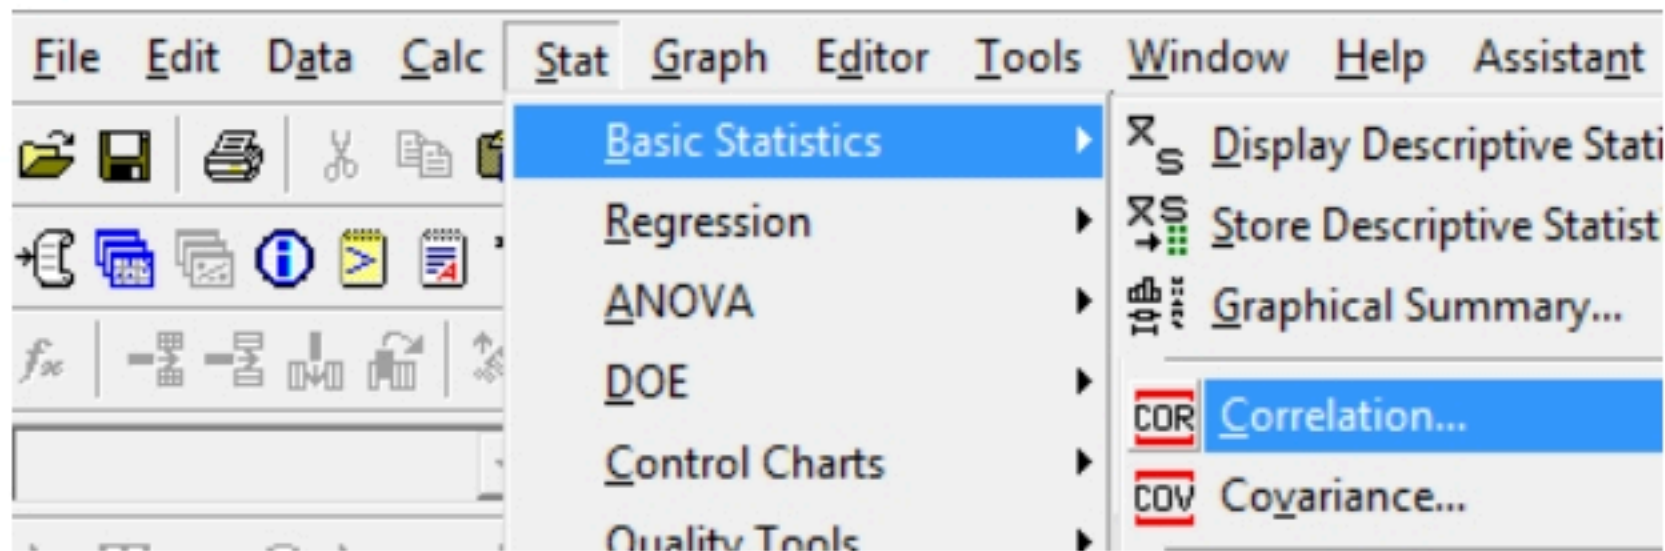
أ- من أجل بيانات المثال ١ / من (١, ٢, ١, ٣) نجد أن:

$$\bar{x} = 75.9 \quad \& \quad S_X = 12.467 \quad \& \quad \bar{y} = 72.6 \quad \& \quad S_Y = 16.029 \quad \& \quad S_{X,Y} = 5740804$$

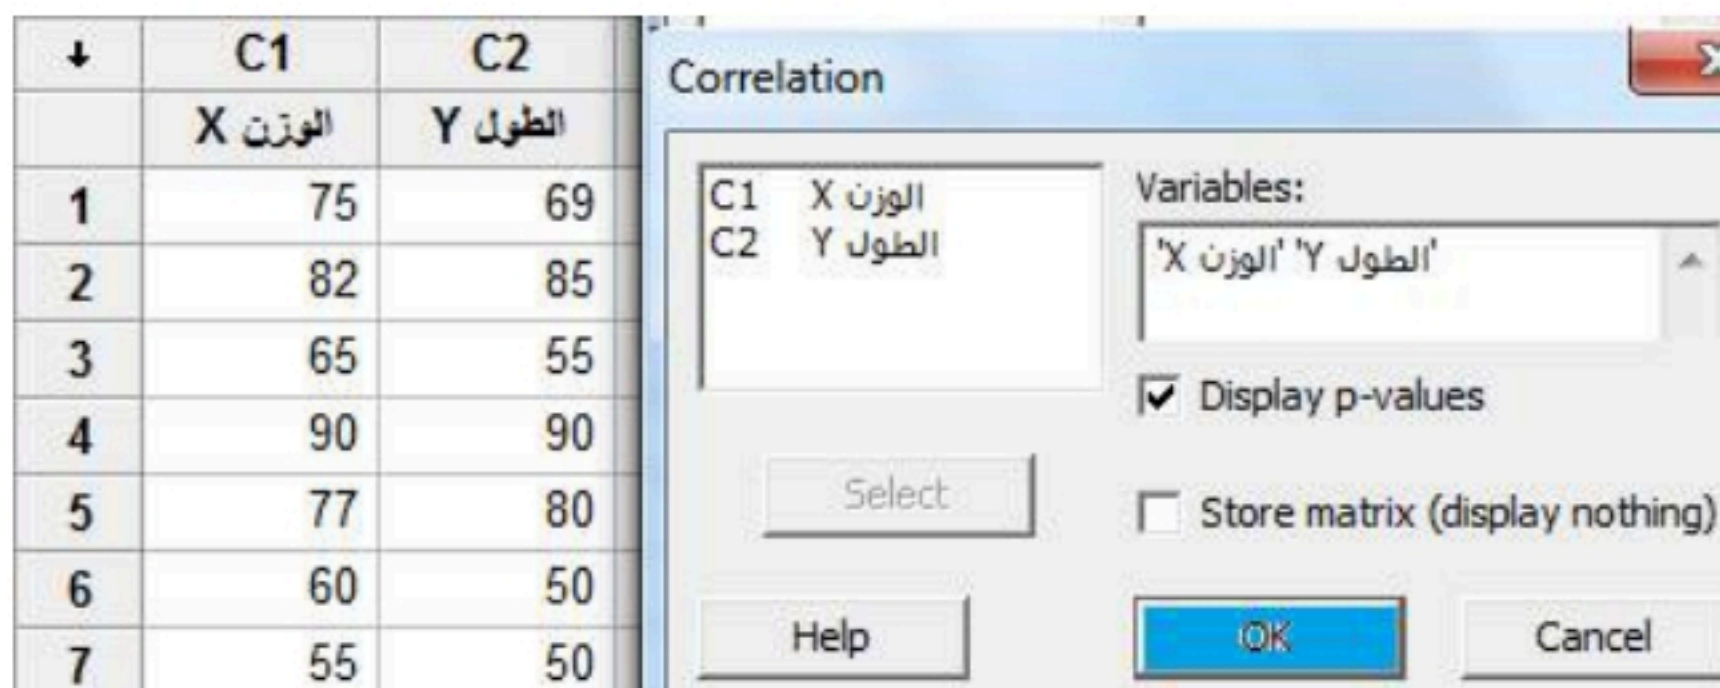
ومن ثم تكون قيمة معامل بيرسون للارتباط الخطي بين بيانات X و Y تساوي:

$$r_p = \frac{S_{X,Y}}{S_X \cdot S_Y} = \frac{5740804}{12.467 \times 16.029} = 0.965$$

فلاحظ هنا إن الارتباط الخطي بين البيانات X و Y إيجابي قوي جداً لأن قيمته قريبة جداً من +1 (انظر إلى منحى هذه البيانات في الشكل (١, ٣ ب)). كما يمكن استخدام برنامج Minitab لحساب معامل بيرسون للارتباط الخطي بين بيانات X و Y وفقاً للخطوات الآتية:



ومن ثم



فنحصل على التقرير الآتي:

Correlations: X الوزن ; Y الطول

Pearson correlation of X and Y = 0.965

ب- من أجل بيانات المثال / ٢ / من (١, ٢, ١, ٣) نجد ما يلي:

$$\bar{x} = 53.1 \quad \& \quad S_X = 21.005$$

$$\bar{y} = 120.5 \quad \& \quad S_Y = 10.080 \quad \& \quad S_{X,Y} = -207.611$$

ومن ثم تكون قيمة r_P لبيانات X و Y هي:

$$r_P = \frac{S_{X,Y}}{S_X \cdot S_Y} = \frac{-207.611}{21.467 \times 10.080} = -0.959$$

وكما نلاحظ أن الارتباط الخطي بين البيانات X و Y سلبي وقوي جداً لأن قيمته قريبة جداً من -1 (انظر إلى منحى هذه البيانات في الشكل (٢, ٣, ب)).

ج- من أجل بيانات المثال / ٣ / من (١, ٢, ١, ٣) نجد القيم الآتية:


$$\bar{x} = 37.813 \quad \& \quad S_X = 6.9595$$

$$\bar{y} = 35.375 \quad \& \quad S_Y = 13.246 \quad \& \quad S_{X,Y} = 6.342$$

ومنه ينتج لدينا أن قيمة r_P لبيانات X و Y تساوي:

$$r_P = \frac{S_{X,Y}}{S_X \cdot S_Y} = \frac{6.342}{6.959 \times 13.246} = 0.069$$

فنلاحظ أن الارتباط الخطي بين بيانات X و Y إيجابي وضعيف جداً لأن قيمته قريبة من الصفر (انظر إلى منحى هذه البيانات في الشكل الآتي).



الشكل (١١, ٣)

كما أننا نلاحظ أن منحى النقاط الممثلة للبيانات يكاد يكون أفقياً، ولكن هذا لا يعني أن صغر ميل هذا المنحى هو السبب في ضعف الارتباط، وهذا ما أشرنا إليه سابقاً.

٢- بالرجوع إلى المثال (٢, ٣, ١, ٣) والمحملة في الجدول (٥, ٣)، فإنه بعد إجراء العمليات الحسابية لبعض المقادير المطلوبة من أجل حساب معامل بيرسون للارتباط الخطي نجد ما يلي:

$$\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij} (x_i - \bar{x}) (y_j - \bar{y}) = 4462.51 \quad \& \quad S_X = 13.350 \quad \& \quad S_Y = 4.943 \quad \& \quad \sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij} = 87$$

ومن ثم تكون قيمة معامل بيرسون للارتباط الخطي هي:


$$r_p = \frac{\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij} (x_i - \bar{x}) (y_j - \bar{y})}{S_X S_Y \left(\sum_{i=1}^k \sum_{j=1}^{\ell} f_{ij} - 1 \right)} = \frac{4462.51}{(13.350) \cdot (4.943) \cdot (86)} = 0.786$$

حيث نلاحظ أنَّ الارتباط بين بيانات المتغيرين X و Y إيجابي وقوي.

الآن لو قمنا الآن بحساب معامل بيرسون للارتباط الخطي للبيانات الخام ذاتها (قبل صيغها في جدول توزيع تكراري) سنجد باستخدام العلاقة [3,5-d] ما يلي:

$$r_p = \frac{n \cdot \left(\sum_{i=1}^n x_i y_i \right) - \left(\sum_{i=1}^n x_i \right) \cdot \left(\sum_{i=1}^n y_i \right)}{\sqrt{n \cdot \left(\sum_{i=1}^n x_i^2 \right) - \left(\sum_{i=1}^n x_i \right)^2} \cdot \sqrt{n \cdot \left(\sum_{i=1}^n y_i^2 \right) - \left(\sum_{i=1}^n y_i \right)^2}} = 0.987$$

وهذه العلاقة الأخيرة تُظهر لنا أنَّ الارتباط بين مجموعتي البيانات X و Y إيجابي وقوي جداً، فلو أمعنا النظر في تمثيل البيانات على لوحة الانتشار (انظر الشكل الآتي (٣، ١٢)) فإننا سنلاحظ قوة الارتباط بين المقررين بسبب وقوع القسم الأكبر من البيانات على مستقيم واحد أو بالقرب منه. بالطبع إنَّ سبب وجود فارق بين القيمتين لـ r_p يكمن في عملية صَبِّ البيانات في جدول التوزيع التكراري حيث مُثلت البيانات المجمعة بمراكز الفئات، وقد أشرنا إلى تأثير ذلك سابقاً في الفصل الثاني.



الشكل (٣، ١٢)

٣- تقدّم ثمانية أشخاص لامتحان تحريري وآخر مقابلة في مقرر الإحصاء، حيث كانت نتائج الاختبار التحريري بالدرجات (الدرجة القصوى 60) في حين كانت نتائج اختبار المقابلة بالتقديرات (ممتاز- جيد جداً- جيد- وسط- ضعيف)، وكانت نتائجهم كما في الجدول الآتي:

الشكل (٣، ١٠)

الطالب	A	B	C	D	E	F	G	H
نتائج الاختبار التحريري X	48	38	32	50	50	38	55	55
نتائج اختبار المقابلة Y	جيد	وسط	وسط	جيد	جيد	وسط	جيد	جيد جداً

ولنقم بدراسة الارتباط بين نتائج الامتحان التحريري والمقابلة لهؤلاء الأشخاص.

نلاحظ أنَّ البيانات المقدّمة من النوع المختلط لَمِيَّة ونوعِيَّة، ولذلك سنستخدم معامل سبيرمان لارتباط الرتب، ومن أجل

ذلك سنضع رتباً بقيم متزايدة للبيانات معتمدين في ذلك الترتيب التنازلي (أو التصاعدي)، فمن أجل نتائج الاختبار التحريري سنبدأ بأول بيان (وهو القيمة 55) ونعطيه الرتبة 1 ثم نعطي الرتبة 2 للبيان المساوي له إن وجد وإلا أعطيت للقيمة التي تليها، وهكذا حتى ننتهي من عملية إعطاء الرتب الأولية للبيانات الكمية الناتجة عن الاختبار التحريري. وأما من أجل البيانات النوعية الممثلة لاختبار المقابلة فإننا نبدأ بأول بيان وهو جيد جداً (لكي يتماشى مع الأسلوب الذي استخدم من أجل نتائج الاختبار التحريري) فنعطيه الرتبة 1 ثم نعطي الرتبة 2 للبيان المماثل له إن وجدت وإلا أعطيت لأول جيد إن وجد، فإن لم تكن موجودة نعطيها لأول وسط، وهكذا حتى ننتهي من عملية إعطاء الرتب الأولية للبيانات النوعية الناتجة عن اختبار المقابلة، فنكون بذلك قد أنجزنا تعيين الرتب الأولية للبيانات. بعد ذلك نحسب المتوسط لرتب البيانات المتماثلة ونستخدمها كرتبة لكل من البيانات المتماثلة فنحصل على الرتب النهائية للبيانات.

الخطوة التالية نقوم بحساب الفروق بين الرتب النهائية المتقابلة ونقوم بحساب مربعاتها، فتكون نتائج هذه العمليات كما في الجدول الآتي:

الشكل (١١، ٣)

الطالب	A	B	C	D	E	F	G	H
نتائج الاختبار التحريري X	48	38	32	50	50	38	55	55
الرتب الأولية α_i	5	7	8	4	3	6	2	1
الرتب النهائية α_i^*	5	6.5	8	3.5	3.5	6.5	1.5	1.5
نتائج اختبار المقابلة Y	جيد	وسط	وسط	جيد	جيد	وسط	جيد	جيد جداً
الرتب الأولية β_i	2	6	7	3	4	8	5	1
الرتب النهائية β_i^*	3.5	7	7	3.5	3.5	7	3.5	1
$d_i = \alpha_i^* - \beta_i^*$	1.5	-0.5	1	0	0	-0.5	-2	0.5
d_i^2	2.25	0.25	1	0	0	0.25	4	0.25

ف نجد أن $\sum_{i=1}^n d_i^2 = 8$ ، ومن ثم قيمة معامل سبيرمان لارتباط الرتب والخاص ببيانات X و Y تساوي:

$$r_s = 1 - \frac{6 \cdot \sum_{i=1}^n d_i^2}{n \cdot (n^2 - 1)} = 1 - \frac{6 \times 8}{8(64 - 1)} = 0.905$$


وهكذا نجد أن الارتباط بين الاختبارين إيجابي وقوي جداً، وهذا يعني أن نتائج الاختبارين التحريري والمقابلة لمقرّر الإحصاء أظهرت أن قدرات الأشخاص لا تتغير كثيراً بتغير نوع الاختبار.

٤- تم تدريب عشرة أشخاص على نوع من التجارب، بحيث يدرب الشخص k لعدد من المرات يساوي x_k مرة، وليكن X متغيراً يرصد التكرارات التي قام بها المتدربون. بعد ذلك يخضع كل متدرب لاختبار فيحصل على درجة y_k من 15 (أي إن الدرجة القصوى 15)، ولنفترض أن المتغير Y يرصد التقييم بالدرجات للمتدربين. الآن بفرض أن نتائج المتدربين كانت كما في الجدول الآتي:

الشكل (١٢، ٣)

الشخص	A	B	C	D	E	F	G	H	I	J
عدد مرات التدريب X	7	5	9	9	7	8	13	8	6	8
درجة الاختبار Y	9	6	9	8	7	7	14	7	5	8

فنجده العرض الانتشاري للبيانات المقدمة في هذا الجدول السابق له الشكل الآتي.



الشكل (٣، ١٣)

ولنقم بدراسة الارتباط الخطي بين المتغيرين X و Y باستخدام معامل سبيرمان الرتبي.

من أجل ذلك لنأخذ رتبا بقيم متزايدة للبيانات معتمدين في ذلك الترتيب التنازلي، كأن نبدأ من أجل قيم X بأعلى قيمة وهي 13 فتعطى الرتبة 1، ثم نعطي الرتبة 2 للبيان 9 ومن ثم 3 للبيان 9، ونتابع على هذا المنوال، فنحصل بذلك على الرتب الأولية للبيانات X ، وبعد ذلك نحسب المتوسط لرتب البيانات المتماثلة ويستخدم كرتبة لكل من هذه البيانات المتماثلة فنحصل على الرتب النهائية لبيانات X ، وبشكل مماثل لما سبق نعالج مجموعة بيانات Y ، فتصبح نتائج هذه العمليات كما في الجدول الآتي:

الشكل (٣، ١٣)

الشخص	A	B	C	D	E	F	G	H	I	J
عدد مرّات التدريب X	7	5	9	9	7	8	13	8	6	8
الرتب الأولية α_i	8	10	3	2	7	6	1	5	9	4
الرتب النهائية α_i^*	7.5	10	2.5	2.5	7.5	5	1	5	9	5
درجة الاختبار Y	9	6	9	8	7	7	14	7	5	8
الرتب الأولية β_i	3	9	2	5	8	7	1	6	10	4
الرتب النهائية β_i^*	2.5	9	2.5	4.5	7	7	1	7	10	4.5
$d_i = \alpha_i^* - \beta_i^*$	5	1	0	-2	0.5	-2	0	-2	-1	0.5
d_i^2	25	1	0	4	0.25	4	0	4	1	0.25

فنجده أن $\sum_{i=1}^n d_i^2 = 39.5$ ، وهكذا تكون قيمة معامل سبيرمان لارتباط الرتب للبيانات المقدمة تساوي:

$$r_s = 1 - \frac{6 \cdot \sum_{i=1}^n d_i^2}{n \cdot (n^2 - 1)} = 1 - \frac{6 \times 39.5}{10(100 - 1)} = 0.761$$

وهكذا نلاحظ وجود ارتباط إيجابي قوي بين عدد مرّات التدريب ودرجة الاختبار، وهذا يعني أنه كلما تلقى المتدرب دورات تدريبية أكثر فإنه يحصل على نتائج أفضل.

الآن، ومن أجل مقارنة معاملي بيرسون وسبيرمان للارتباط الخطي سنقوم بحساب معامل بيرسون للارتباط الخطي والخاص بالبيانات السابقة. حيث لدينا:

الشكل (١٤، ٣)

i	x_i	x_i^2	y_i	y_i^2	$x_i \cdot y_i$
1	7	49	9	81	63
2	5	25	6	36	30
3	9	81	9	81	81
4	9	81	8	64	72
5	7	49	7	49	49
6	8	64	7	49	56
7	13	169	14	196	182
8	8	64	7	49	56
9	6	36	5	25	30
10	8	64	8	64	64
sum	80	682	80	694	683

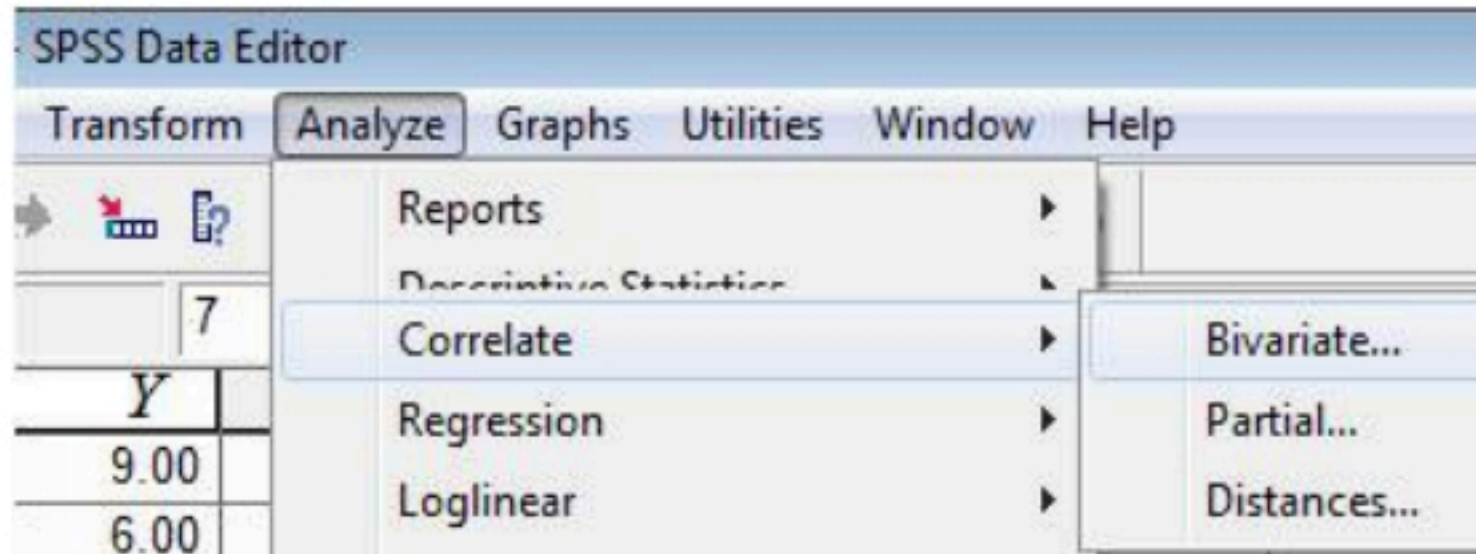
ومن ثم نجد أن قيمة معامل بيرسون للارتباط الخطي بين بيانات X و Y تساوي:

$$r_P = \frac{n \cdot \left(\sum_{i=1}^n x_i y_i \right) - \left(\sum_{i=1}^n x_i \right) \cdot \left(\sum_{i=1}^n y_i \right)}{\sqrt{n \cdot \left(\sum_{i=1}^n x_i^2 \right) - \left(\sum_{i=1}^n x_i \right)^2} \cdot \sqrt{n \cdot \left(\sum_{i=1}^n y_i^2 \right) - \left(\sum_{i=1}^n y_i \right)^2}} = \frac{430}{(20.494)(23.238)} = 0.903$$

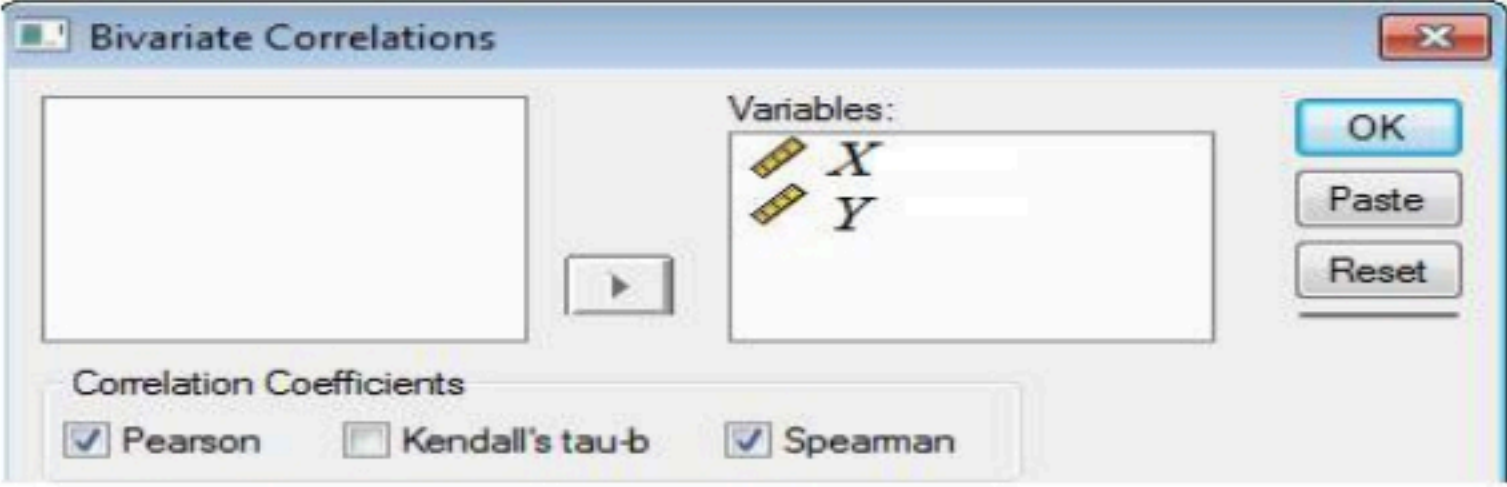
وهذا يعني وجود ارتباط إيجابي قوي جداً بين عدد مرّات التدريب ودرجة الاختبار.

لاحظ أن الفارق بين نتيجتي المعاملين (لـ **بيرسون وسبيرمان**) هو أمر طبيعي ومتوقع أيضاً لأنّ معامل سبيرمان لا يأخذ قيم البيانات بالحسبان وإنّما يعتمد على رتبها فقط.

كما يمكن استخدام برنامج SPSS لحساب معامل سبيرمان و بيرسون للارتباط الخطي بين بيانات X و Y وفقاً للخطوات الآتية:



ومن ثم



فنحصل على تقرير فيه الجزء الذي يهمنا هو الآتي:

	X	Y
Spearman's rho	1.000	.752
Correlation Coefficient		


الذي يعطينا $r_s = 0.752$ ، وهذه القيمة تختلف قليلاً عن القيمة التي قمنا بحسابها لهذا المعامل، وسبب هذا الفرق يعود لاستخدام البرنامج صيغة معدلة في عملية الحساب.

(٣, ١, ٥, ٣) ملاحظات


١- يعدّ معامل بيرسون للارتباط الخطي أكثر دقة من معامل سبيرمان لارتباط الرتب في تعيين درجة الارتباط الخطي، بمعنى أنه إذا كانت البيانات التي هي قيد الدراسة هي بيانات كمية كاملة (أي لا يوجد فيها بيانات مفقودة)، فعندئذ من المفضل استخدام معامل بيرسون للارتباط الخطي.

٢- إذا لاحظنا وجود بيانات مفقودة ولكن ترتبها بين البيانات وتبعيتها للعناصر المدروسة معلوماً، فعندئذ يمكن اللجوء إلى استخدام معامل سبيرمان لارتباط الرتب.

٣- إذا كانت مجموعة البيانات لا تحتوي على بيانات متطرفة (أو شاذة في سلوكها) فعندئذ ستكون قيمتي معامل بيرسون للارتباط الخطي ومعامل سبيرمان لارتباط الرتب قريبتين من بعضهما (انظر الشكل (١٢, ٣, أ)).



الشكل (١٤, ٣, ب)



الشكل (١٤, ٣, أ)

وأما إذا كانت مجموعة البيانات تحتوي على بعض البيانات المتطرفة (أو الشاذة في سلوكها)، فعندئذ سيكون هناك فارق (قد يكون كبيراً نسبياً) بين قيمتي معامل بيرسون للارتباط الخطي ومعامل سبيرمان لارتباط الرتب (انظر الشكل السابق (١٢, ٣, ب))، ولذلك يفضل استخدام معامل سبيرمان لارتباط الرتب في هذه الحالة بسبب تأثر المتوسط الحسابي (ومن ثمّ معامل بيرسون للارتباط الخطي) بالقيم المتطرفة.

٤- إن مربع قيمة معامل الارتباط (سواء كانت لعينة أو لمجتمع) تدعى **معامل التحديد** Coefficient of Determination، ويرمز له بـ r^2 أو ρ^2 (وفي بعض البرامج الإحصائية يُشار إليه بـ **R-square**)، وهذه القيمة تستعمل كتقدير لقوة علاقة الارتباط بين متغيرين أيضاً. إن النسبة المئوية لمعامل التحديد $r^2\%$ تشكّل مقدار تغيّر الظاهرة X المرتبطة مع تغيّر Y ، فعلى سبيل المثال (في الكيمياء الحيوية) إذا كانت قيمة معامل الارتباط لكمية الكلوروفيل α والمادة العضوية تساوي $r = 0.50$ فإنّ معامل التحديد $r^2 = 0.25$ يدلّ على أنّ 25% من التغيّر في أحد المتغيرين مرتبطة بالمتغيّر الآخر (أو توضّح من خلال تغيّر المتغيّر الآخر)، أو بتعبير آخر نقول إنّ 75% من التغيّر في أحد المتغيرين لم توضّح بوساطة التغيّر الذي حصل للمتغيّر الآخر.

معامل الارتباط Coefficient of Association (٣.١, ٦)

في كثير من الأحيان (وخاصة لدى الدراسات الاجتماعية أو السلوكية) تكون البيانات المعطاة مجمعة في جدول ولكن هذه البيانات نوعية مثل: قوي وضعيف، ذكي وغبى، ذكر وأنثى وعلى هذا المنوال. بالطبع قد قمنا سابقاً بتقديم معامل سبيرمان لارتباط الرتب الذي يمكن استخدامه من أجل البيانات النوعية التي يمكن ترتيبها، وأما من أجل الحالة التي لا يمكن ترتيب البيانات فيها، أو إن رُتبت فلا أهمية لترتيبها، فإن معامل سبيرمان لارتباط الرتب يصبح غير قابل للتطبيق، ولذلك لابد من إيجاد مقاييس خاصة تتعامل مع هذه البيانات.

لقد وضع الإحصائي البريطاني يول (George Udny Yule (1871–1951) مقياساً لدراسة درجة ونوعية الارتباط بين ظاهرتين بياناتهما نوعية أو كمية وتنقسم كل منهما إلى نوعين أو مجموعتين فقط (مثل: قوي وضعيف – سريع وبطيء...)، وأسماه **معامل الارتباط**، وفي مثل هذه الحالة تكون البيانات المتاحة للباحث كما في الجدول الآتي:

الشكل (٣, ١٥)

		الظاهرة الأولى X	
		عدد العناصر التي حققت الظاهرة الأولى	عدد العناصر التي لم تحقق الظاهرة الأولى
الظاهرة الثانية Y	عدد العناصر التي حققت الظاهرة الثانية	a	b
	عدد العناصر التي لم تحقق الظاهرة الثانية	c	d

عندئذ يُحسب معامل الارتباط بين هاتين الظاهرتين من خلال العلاقة الآتية:

$$r_{CA} := \frac{ad - bc}{ad + bc} \quad [3,10]$$

علماً أن اقتراب قيمة r_{CA} من القيمة 0 تعني ضعف الارتباط بين الظاهرتين، وأما اقتراب قيمة r_{CA} من القيمة ± 1 فإنها تعني اقتراب درجة الارتباط من الكمال بين الظاهرتين إيجابياً (عندما تكون الإشارة موجبة) أو عكسياً (عندما تكون الإشارة سالبة).

مثال (٣, ١, ٦, ١)

في دراسة لمعرفة مدى تأثير مرور تيار أعلى من المسموح به في مقاومة أومية ذات استطاعة 0.5W واط توفرت لدينا البيانات الآتية:

الشكل (٣, ١٦)

		الظاهرة الأولى (العريض للتيار)	
		عدد العناصر التي عُرِضت لتيار أعلى من المسموح به	عدد العناصر التي لم تُعْرَض لتيار أعلى من المسموح به
الظاهرة الثانية (الإصابة بالتلف)	عدد العناصر التي أصبحت بالتلف	131	78
	عدد العناصر التي لم تصب بالتلف	52	318

فنجِد من هذه البيانات أن:

$$r_{CA} = \frac{131 \times 318 - 78 \times 52}{131 \times 318 + 78 \times 52} = \frac{37602}{45714} = 0.823$$

وهذا يعني وجود ارتباط طردي قوي بين تعرض المقاومة لتيار أعلى من المسموح به وتلفها، أو يقال إن تلف المقاومة غير مستقل عن تعرضها لتيار أعلى من المسموح به.

قد يكون لدينا ظواهر ذات بيانات نوعية أو كمية، وتتجزأ في أكثر من نوعين أو مجموعتين، فعندئذ نلاحظ أن معامل الاقتران لا يقدم لنا أية مساعدة في هذا المجال، ولذلك لا بد من مقياس آخر يتعامل مع هذه المعطيات. لقد قام بيرسون بوضع مقياس لدراسة درجة ونوعية الارتباط لمثل هذه المعطيات، وأطلق عليه اسم **معامل التوافق** الذي تقدمه الفقرة الآتية.

(٣, ١, ٧) معامل التوافق Coefficient of Contingency

لتكن لدينا مجموعة بيانات حجمها n ومعطاة كما في الجدول الآتي:

الشكل (٣, ١٧)

		بيانات المتغير X				Total
		x_1	x_2	x_k	
بيانات المتغير Y	y_1	a_{11}	a_{12}	a_{1k}	$n_{1 \cdot}$
	y_2	a_{21}	a_{22}	a_{2k}	$n_{2 \cdot}$
	\vdots	\vdots	\vdots	\vdots	\vdots
	y_ℓ	$a_{\ell 1}$	$a_{\ell 2}$	$a_{\ell k}$	$n_{\ell \cdot}$
Total		$n_{\cdot 1}$	$n_{\cdot 2}$	$n_{\cdot k}$	n

علماً أن a_{ij} هي القيمة الواقعة في العمود i والصف j وتشير إلى عدد البيانات الموافقة لـ x_i و y_j معاً، وأما $n_{j \cdot}$ و $n_{\cdot i}$ فإنهما يحسبان من أجل كل $N_\ell \ni j$ و $N_k \ni i$ كما يلي:

$$n_{j \cdot} = \sum_{i=1}^k a_{ji} \quad \& \quad n_{\cdot i} = \sum_{j=1}^{\ell} a_{ji}$$

عندئذ يُعطى **معامل التوافق** لهذه البيانات (وسنرمز له بـ r_{CC}) بالعلاقة الآتية:

$$r_{CC} = \sqrt{\frac{G}{G+n}} \quad [3,11]$$

علماً أن G مُحسب كما يلي:

$$G = n \left(\sum_{i=1}^k \sum_{j=1}^{\ell} \frac{(a_{ij})^2}{n_{j \cdot} \cdot n_{\cdot i}} \right) - n \quad [3,12]$$

والمثال الآتي يوضح ذلك.

(٣, ١, ٧, ١) مثال

إن الجدول الآتي يعرض لنا المهارات المخبرية لعينة من 473 طالباً في تنفيذ تجربتين X و Y .

الشكل (١٨, ٣)

		بيانات التجربة X				Total
		مقبول	جيد	جيد جداً	ممتاز	
بيانات التجربة Y	مقبول	10	18	23	14	65
	جيد	45	103	82	50	280
	جيد جداً	27	50	30	21	128
Total		82	171	135	85	473

ولنبين نوعية ودرجة الارتباط بين هاتين التجريبتين.

من أجل ذلك لنستخدم صيغة معامل التوافق (العلاقة [3,11]) فنجد أن:

$$G = n \left(\sum_{i=1}^k \sum_{j=1}^{\ell} \frac{(a_{ij})^2}{n_{j \cdot} \cdot n_{\cdot i}} \right) - n = 473 \left(\frac{(10)^2}{(82) \cdot (65)} + \frac{(18)^2}{(171) \cdot (65)} + \frac{(23)^2}{(135) \cdot (65)} + \frac{(14)^2}{(85) \cdot (65)} \right. \\ \left. + \frac{(45)^2}{(82) \cdot (280)} + \dots + \frac{(30)^2}{(135) \cdot (128)} + \frac{(21)^2}{(85) \cdot (128)} \right) - 473$$

$$= 473 \times 1.0066 - 473 = 3.1218$$

ومن ثم نجد قيمة معامل التوافق لهذه البيانات هي:

$$r_{CC} = \sqrt{\frac{G}{G+n}} = \sqrt{\frac{3.1218}{3.1218+473}} = 0.081$$

وهذا يعني أن التجريبتين ترتبطان مع بعضهما ارتباطاً إيجابياً، ولكنّ درجة هذا الارتباط ضعيفة جداً.

٣,٢ الانحدار الخطي البسيط

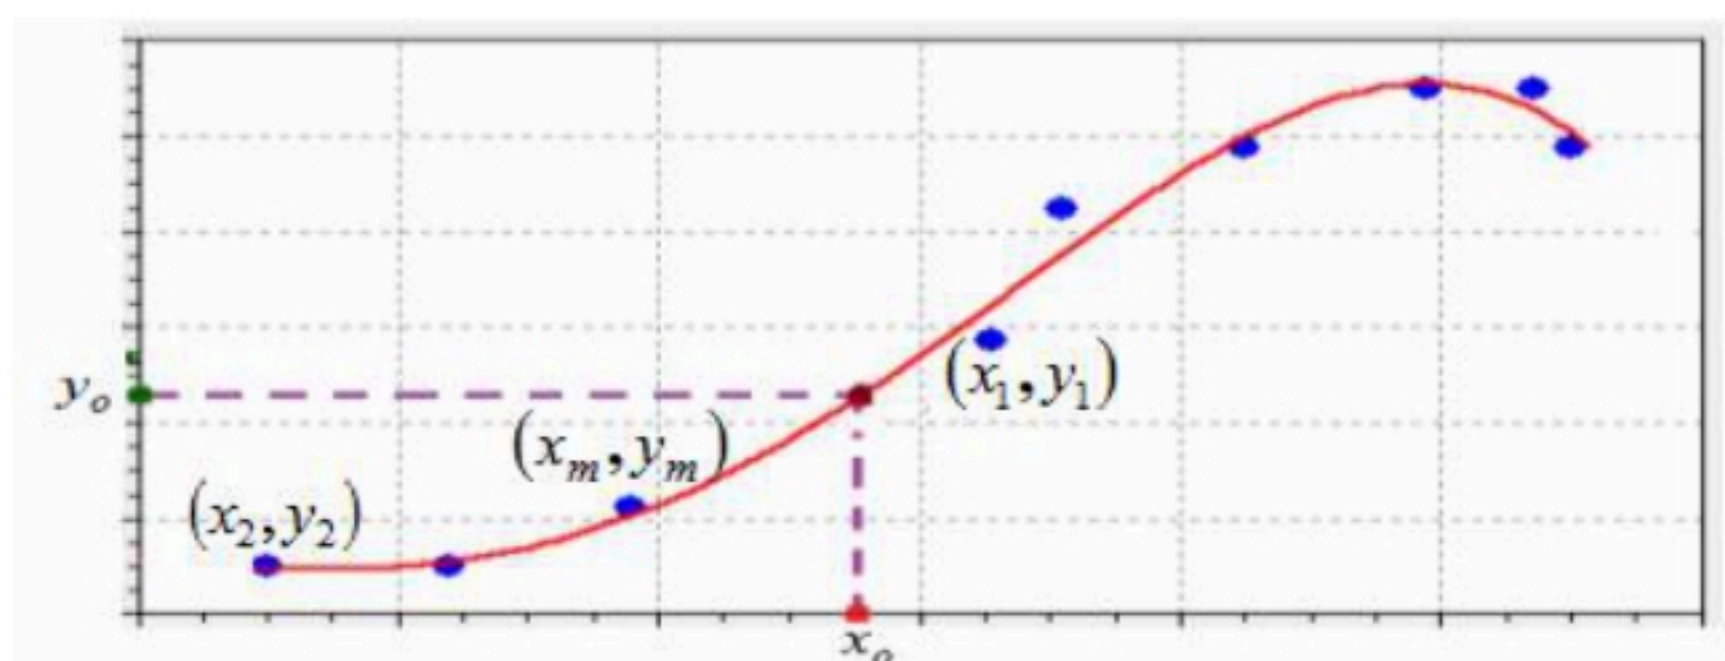
Simple Linear Regression

قمنا فيما سبق بدراسة الارتباط لظاهرتين ومن ثمّ قياس درجة الارتباط وفق طرائق مختلفة تتناسب كل منها وحالة معينة لطبيعة البيانات، ولكن إذا توقفنا عند هذه المرحلة فإنّ الفائدة ستكون محدودة، وذلك أنّه من الأفضل (وبناءً على وجود تلك العلاقة للارتباط بين ظاهرتين) استخدام تلك الحقيقة في تقدير قيمة متغيّر إذا ما علمنا قيمة أو أكثر للمتغيّر الآخر. إنّ تقدير قيمة متغيّر إذا ما علمت علاقة الارتباط بين هذا المتغيّر ومتغيّر آخر مبني على ما يُسمّى بتحليل الانحدار. في الواقع إنّ الانحدار هو تمثيل للعلاقة المتوسطة بين المتغيّرات، فإذا وجدت علاقة تربط بين المتغيّرات المطلوب دراستها فإنّه يمكن توفيق معادلة منحنى أو خط يحدّد طبيعة تلك العلاقة، ومن ثمّ يمكننا استخدام ذلك المنحنى أو الخط لتقدير القيم النظرية لمتغيّر إذا علمت القيم للمتغيّر الآخر. هكذا نجد أنّه يمكن استخدام تحليل الانحدار لتقدير قيمة متغيّر تابع (المتغيّر الذي نودّ تعليله) بناءً على قيمة واحدة على الأقل من قيم المتغيّر المستقل (المتغيّر المستخدم لتعليل المتغيّر التابع)، ومن ثمّ إمكانية شرح تأثير التغيّرات في المتغيّر المستقل على المتغيّر التابع.

أمّا من حيث نشأة مفهوم الانحدار، فقد جاءت من دراسات في علم الوراثة للإحصائي وعالم الوراثة والنفس والاجتماع الإنكليزي غالتون Sir Francis Galton (1822-1911) (خلال أواخر القرن التاسع عشر) عند تقديم دراسته حول العلاقة التي تربط بين أعمار الآباء والأبناء لأجيال متعاقبة عديدة، وذلك بغية استقراء واقع تطور العمر لدى العنصر البشري، فوجد أنّ أعمار الأبناء في حالة انحسار متواصل عبر الأجيال المتعاقبة، وكذلك لاحظ غالتون أن خصائص محدّدة مثل الطول في الآباء لا تنتقل تماماً إلى ذرياتهم (الطول في حالة انحسار أيضاً)، وعبر عن ذلك بالقول: إنّ أعمار الأبناء في حالة انحدار لأنّ التمثيل البياني لها كان منحدرًا، ومن هنا جاءت تسمية

تحليل الانحدار. في الواقع من الممكن أن تكون العلاقة التي تربط بين متغيرات أخرى متعلقة بعناصر عينة (أو مجتمع) ما هي علاقة لها منحنى صاعد وليس منحدراً (أو هابطاً) كالعلاقة التي تربط بين الطول والوزن لمجموعة من البشر.


لنفترض الآن أنه لدينا (x_1, y_1) ، (x_2, y_2) ، ...، (x_n, y_n) مجموعة منتهية من المشاهدات الناتجة عن متغيرين X و Y ، ولنفترض على سبيل المثال أن تمثيلها على لوحة الانتشار له العرض المقدم في الشكل الآتي (أ. ٣، ١٥)، فعندئذ من أولى مهام تحليل الانحدار تمكيننا من تقدير (أو تخمين) قيمة y_o مقابلة لقيمة x_o مجهولة تقع ضمن نطاق البيانات الأصلية x_1, x_2, \dots, x_n ، وكذلك يساعدنا في بعض الحالات على التنبؤ بقيمة y_o مقابلة لقيمة x_o التي تقع خارج نطاق البيانات الأصلية x_1, x_2, \dots, x_n .



الشكل (١٥، ٣. أ)

بالطبع إن أفضل تقدير لهذه القيمة ينتج عن استخدام الدالة التي يمر رسمها البياني من جميع النقاط الممثلة للبيانات، ولكن تعيين معادلة هذه الدالة في الحالة العامة قد يكون صعباً جداً إن لم يكن غير ممكن في بعض الحالات، ولذلك يبحث المرء في تعيين الدالة التي رسمها البياني يمر من بعض هذه النقاط وبالقرب من بعضها الآخر إن أمكن ذلك (كما في الشكل (أ. ٣، ١٥))، وتعيين مثل هذه الدالة يحتاج في معظم الأحيان إلى برامج خاصة بتوفيق المنحنيات Curves Fitting.

سنبحث فيما يلي في أبسط أنواع العلاقات التي تربط بين متغيرين X و Y ، وهي تدعى **معادلة الانحدار الخطي البسيط**، وعبارة بسيط هنا تعني حالة وجود متغيرين فقط. أي إننا سنسعى لتعيين الدالة التي رسمها البياني مستقيم يمر من جميع هذه النقاط أو يمر من بعض هذه النقاط وبالقرب من بعضها الآخر إن أمكن ذلك، وإن لم يكن ذلك ممكناً فليكن المستقيم الذي يمر بالقرب من هذه النقاط كما في الشكل (ب. ٣، ١٥) الآتي:






الشكل (١٥، ٣. ب)

في الحقيقة توجد طرائق عديدة لتعيين العلاقة الخطية التي تربط بين متغيرين X و Y وستتناول هنا إحدى هذه الطرائق التي تدعى **طريقة المربعات الصغرى**.

(١, ٢, ٣) طريقة المربعات الصغرى Least Square Method


لقد نُشرت أول مقالة واضحة وموجزة لطريقة المربعات الصغرى من قبل الرياضي الفرنسي **ليجاندر** Adrien-Marie Legendre (1752-1833) في عام 1805، حيث وصفت هذه التقنية على أنها الإجراءات الجبرية لتوفيق معادلات خطية للبيانات، وقد استعرض **ليجاندر** طريقته الجديدة من خلال تحليل البيانات نفسها كما فعل **لابلاس** لشكل الأرض. لقد لاقت طريقة المربعات الصغرى المقدمة من **ليجاندر** اعترافاً مباشراً من قبل كبار علماء الفلك والمساحة (**الجيوڨيسيا**) في ذلك الزمان. إنَّ طريقة المربعات الصغرى هي إحدى الطرائق المستخدمة في توفيق المنحنيات لمجموعة منتهية من المشاهدات المُعطاة (**على شكل ثنائيات**) ونتيجة عن تطبيق دراسة متغيرين X و Y على مجموعة من العناصر، وتقوم هذه الطريقة على ركيزتين هما:

- ١- مجموع انحرافات المشاهدات عن النقاط المقابلة لها من هذا المستقيم يساوي الصفر دوماً.
 - ب- جعل مجموع مربعات انحرافات قيم المشاهدات عن المستقيم المُوَقَّ للمشاهدات أصغر ما يمكن.
- عندئذ ينظر إلى هذا المستقيم على أنه أفضل مستقيم يمر بالنقاط الممثلة للمشاهدات وفقاً لطريقة المربعات الصغرى. بالطبع توجد طرائق عديدة لتفسير البندين (أ) و (ب) السابقين (**انظر العروض الآتية لتوضيح ذلك**) ومنها:
- ١- طريقة **OLS**: تقوم هذه الطريقة على جعل $\sum (y_i - \hat{y}_i)^2$ أو $\sum (x_i - \hat{x}_i)^2$ أصغر ما يمكن. علماً أنَّ \hat{y}_i هي القيمة المقدرة لـ y عند إعطاء قيمة x_i ، وأما \hat{x}_i فهي القيمة المقدرة لـ x عند إعطاء قيمة y_i وفقاً لمعادلة المستقيم المُوَقَّ للمشاهدات.




- ٢- طريقة **BMLS**: تقوم هذه الطريقة على جعل المقدار الآتي أصغر ما يمكن:

$$\sum_i |(y_i - \hat{y}_i) \cdot (x_i - \hat{x}_i)|$$



- ٣- طريقة **BSLS**: تقوم هذه الطريقة على جعل المجموع أصغر ما يمكن:

$$\sum_i [(y_i - \hat{y}_i)^2 + (x_i - \hat{x}_i)^2]$$



٤- طريقة **BPLS**: تقوم هذه الطريقة على جعل مجموع مربع المسافات الناتجة عن الإسقاط العمودي للنقاط (x_i, y_i) على مستقيم الموفق للملاحظات أصغر ما يمكن.

فيما يلي سنعتمد على طريقة المربعات الصغرى العادية Ordinary Least Squares Method (طريقة **OLS**) فقط لتعيين معادلة مستقيم الانحدار، وسنذكرها باسم **طريقة المربعات الصغرى** على سبيل التبسيط، ووفقاً لهذه الطريقة سنناقش الحالتين الموافقتين لبيانات عينة ومن ثم لبيانات مجتمع.

(٣, ٢, ٢) معادلتا مستقيما الانحدار لبيانات عينة Equations of Straights Regression for Sample Data

بفرض أن $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ بيانات عينة أخضعت لدراسة متغيرين X و Y ، فعندئذ لتعيين مستقيم المربعات الصغرى لمجموعة البيانات المعطاة سنميز بين نوعين من المستقيمات هما:


(٣, ٢, ٢, ١) معادلة مستقيم انحدار Y على X Equation of Straight Regression of Y on X

إذا كان الهدف تعيين قيمة \hat{y}_i كتقدير لقيمة y_i باستخدام هذا المستقيم لدى إعطاء قيمة محددة لـ x_i (انظر الشكل الآتي)، فعندئذ يكون لمعادلة مستقيم المربعات الصغرى لهذه البيانات العرض الآتي:

$$\hat{Y} = a + bX \quad [3,13-a]$$

ويُدعى المستقيم الناتج عن هذه العلاقة بـ **مستقيم انحدار Y على X** ، وهي تساعدنا في تقدير قيم Y لدى إعطاء قيم لـ X ، بمعنى أنه من أجل x_i قيمة محددة لـ X فإن القيمة \hat{y}_i المقدرة لـ y_i تحسب وفقاً للصيغة الآتية:

$$\hat{y}_i = a + b x_i \quad ; i \in N_n \quad [3,13-b]$$



إن الفارق بين القيمة الحقيقية y_i والقيمة المقدرة لها \hat{y}_i وفقاً لمعادلة المستقيم [3-13-a] يُدعى **الباقى** Residual أو **الخطأ** Error المرافق لتقدير قيمة y_i بالقيمة \hat{y}_i عند استخدام معادلة المستقيم المعطى بالعلاقة [3-13-a]، ويرمز له بـ ϵ_i ، ومن ثم يمكننا كتابة الصيغة التي تُعطينا البواقي على النحو الآتي:

$$\epsilon_i = y_i - \hat{y}_i \quad ; i \in N_n$$

وهذا المقدار يمكن أن يكون موجباً أو سالباً أو صفراً وذلك بحسب موضع النقطة من المستقيم أهى أعلى المستقيم أو أسفله أم واقعة عليه (انظر الشكل السابق (١٦, ٣)).

إنَّ قيم **متغير الاستجابة** \hat{Y} الذي يلعب دور المتغير التابع في المعادلة [3-13-b] تُدعى **القيم المقدرة** (أو **المتنبأ بها**) Predicted Values (أو **القيم التي تمَّ توفيقها** Fitted Values)، وأما **المتغير التفسيري** X الذي له دور المتغير المستقل في معادلة المستقيم فإنه يُدعى **المتغيرُ المتنبأ به** Predictor Variable. في حين أنَّ a و b هما ثابتان حقيقيان يُطلب تعيينها ويُدعى **معامل الانحدار** (أو **وسطي الانحدار**) Regression Coefficients، علماً أنَّ a يمثل قيمة تقاطع مستقيم الانحدار مع المحور oY في حين يمثل b قيمة الميل لهذا المستقيم. الآن (وكما ذكرنا سابقاً) لتعيين قيم a و b في المعادلة [3-13-a] وفقاً لطريقة المربعات الصغرى يجب أن يكون ما يلي محققاً:

$$\text{i) } \sum_{i=1}^n \varepsilon_i = 0 \quad \& \quad \text{ii) } \sum_{i=1}^n \varepsilon_i^2 = \text{minimal}$$

عندئذ من تحقق الشرط $\sum_{i=1}^n \varepsilon_i = 0$ ينتج لدينا ما يلي:

$$\sum_{i=1}^n (y_i - \hat{y}_i) = 0 \Rightarrow \sum_{i=1}^n y_i = \sum_{i=1}^n \hat{y}_i = b \sum_{i=1}^n x_i + n a \quad (1)$$

ولكي يكون الشرط (ii) محققاً يلزم أن يكون (وذلك باستخدام الاشتقاق الجزئي):

$$\frac{\partial}{\partial b} \sum_{i=1}^n (y_i - \hat{y}_i)^2 = 0 \Rightarrow -2 \sum_{i=1}^n x_i (y_i - (bx_i + a)) = 0$$

ومنها نجد:

$$\sum_{i=1}^n x_i y_i = b \sum_{i=1}^n x_i^2 + a \sum_{i=1}^n x_i \quad (2)$$

وكذلك لدينا:

$$\frac{\partial}{\partial a} \sum_{i=1}^n (y_i - \hat{y}_i)^2 = 0 \Rightarrow -2 \sum_{i=1}^n (y_i - (bx_i + a)) = 0 \Rightarrow \sum_{i=1}^n y_i = b \sum_{i=1}^n x_i + n a$$

وهذه الأخيرة تُطابق العلاقة (1)، ومنه بحل جملة المعادلتين (1) و (2) بالنسبة إلى a و b نجد أنَّ:

$$b = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2} \quad [3,14-a]$$

وهذه يُمكن كتابتها بدلالة قيمة معامل الارتباط الخطي r والانحراف المعياري لكل من X و Y على النحو الآتي أيضاً:

$$b = \frac{S_{X,Y}}{S_X^2} = \frac{S_Y}{S_X} r \quad [3,14-b]$$

وهذه القيمة التي تمثل ميل مستقيم الانحدار تُدعى **معامل انحدار Y على X** ، وأما قيمة a التي تمثل قيمة تقاطع المستقيم مع المحور oY فيكون لها العرض الآتي:

$$a = \frac{\sum_{i=1}^n y_i \sum_{i=1}^n x_i^2 - \sum_{i=1}^n x_i \sum_{i=1}^n x_i y_i}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2} \quad [3,15-a]$$

وهذه العلاقة الأخيرة يُمكن كتابتها بالشكل الآتي أيضاً:

$$a = \frac{\sum_{i=1}^n y_i}{n} - b \frac{\sum_{i=1}^n x_i}{n} = \bar{y} - b \bar{x}$$

أي إن:

$$a = \bar{y} - b \bar{x}$$


[3,15-b]

وهكذا تكون معادلة مستقيم الانحدار معينة تماماً عندما يكون الثابتان a و b قد تم حسابهما من خلال العلاقتين [3-14-a] و [3-15-a] على الترتيب.

إذاً، وفقاً لهذه الطريقة ينظر إلى هذا المستقيم (وَيُدعى مستقيم انحدار Y على X) على أنه أفضل مستقيم يمر بالنقاط (أو بالقرب من النقاط) الممثلة لهذه البيانات، وهذه العلاقة تساعدنا في تقدير (أو التخمين عن) القيمة \hat{y}_o الموافقة لقيمة x_o تقع ضمن نطاق بيانات المتغير X (من الممكن x_o ألا تكون موجودة مع المشاهدات الأصل)، وفي هذه الحالة تُدعى القيمة \hat{y}_o بالقيمة المقدرة لـ Y والموافقة للقيمة المعلومة x_o .

Equation of Straight Regression of X on Y . Y على X انحدار مستقيم

لقد لاحظنا أن معامل بيرسون للارتباط الخطي بين المتغيرين X و Y هو نفسه بين Y و X لأن $S_{X,Y} = S_{Y,X}$ (مصفوفة التباين للمتغيرين متناظرة دوماً)، ولذلك قد يتبادر لذهن القارئ أن يكون مستقيم الانحدار $\hat{Y} = a + bX$ هو $\hat{X} = a + bY$ نفسه. لكن في الواقع هذين المستقيمين مختلفين عن بعضهما في الحالة العامة، وذلك لأن العلاقة [3-13-a] لا تتمتع بخاصية التناظر بـ X و Y ، ومن جهة أخرى فلو عدنا بذاكرتنا قليلاً للأخطاء ε_i فقد حسبنا بناءً على الإسقاط الرأسى (بشكل مواز لـ Y) على مستقيم الانحدار كما في الشكل (٣، ١٦) السابق، فحصلنا نتيجة لذلك على المعادلة $\hat{Y} = a + bX$ ، وأما لو قمنا بحساب الأخطاء ε_i بناءً على الإسقاط الأفقي (الموازي لـ X) على مستقيم الانحدار كما في الشكل الآتي:



الشكل (٣، ١٧)

فعندئذ سنحصل على معادلة أخرى لمستقيم المربعات الصغرى من الشكل:

$$\hat{X} = c + dY$$

[3,16-a]

ومن أجل y_i قيمة محددة لـ Y يصبح لمعادلة هذا المستقيم العرض الآتي:

$$\hat{x}_i = c + d y_i \quad ; i \in N_n$$

[3,16-b]

علماً أنه من أجل كل $i \in N_n$ لدينا \hat{x}_i هي القيمة المقدرة من y_i باستخدام المعادلة [3-16-a]، ومن ثم يكون مقدار انزياح

\hat{x}_i عن x_i هو $\varepsilon_i := x_i - \hat{x}_i$. علماً أن d تُحسب (وبشكل مماثل لما سبق شرحه) بالعلاقة الآتية:

$$d = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n y_i^2 - \left(\sum_{i=1}^n y_i \right)^2} \quad [3,17-a]$$

التي يمكن كتابتها بدلالة قيم معامل الارتباط الخطي \mathbf{r} والانحراف المعياري لكل من X و Y على النحو الآتي أيضاً:

$$d = \frac{S_{X,Y}}{S_Y^2} = \frac{S_X}{S_Y} \mathbf{r} \quad [3,17-b]$$

وهذه القيمة التي تمثل ميل مستقيم الانحدار تُدعى **معامل انحدار X على Y** ، وأما قيمة c التي تمثل قيمة تقاطع هذا المستقيم مع المحور OX فإنها تُحسب بالعلاقة الآتية:

$$c = \frac{\sum_{i=1}^n x_i \sum_{i=1}^n y_i^2 - \sum_{i=1}^n y_i \sum_{i=1}^n x_i y_i}{n \sum_{i=1}^n y_i^2 - \left(\sum_{i=1}^n y_i \right)^2} \quad [3,18-a]$$

ويمكن كتابتها بالشكل الآتي أيضاً:

$$c = \frac{\sum_{i=1}^n x_i}{n} - d \frac{\sum_{i=1}^n y_i}{n} = \bar{y} - d \bar{x}$$

أي إن:

$$c = \bar{y} - d \bar{x} \quad [3,18-b]$$

إن مستقيم المربعات الصغرى والمعطى بالعلاقة [3-16-a] يُدعى **مستقيم انحدار X على Y** ، ومعادلته تساعدنا في تقدير (أو تخمين) القيمة \hat{x}_0 الموافقة لقيمة y_0 (من الممكن ألا تكون موجودة مع المشاهدات) تقع ضمن نطاق بيانات المتغير Y ، وفي هذه الحالة تُدعى القيمة \hat{x}_0 بالقيمة المقدرة لـ X الموافقة للقيمة المعلومة y_0 .

(٣، ٢، ٢، ٣) ملاحظات:

١- إن مستقيم الانحدار المستنتج وفقاً لطريقة المربعات الصغرى يمر بالنقطة التي إحداثيها (\bar{x}, \bar{y}) ، وذلك لأنه من العلاقة [3-15-b] لدينا $\bar{y} = a + b \bar{x}$ ، ومن ثم ينتج أن $\hat{y} - \bar{y} = b(x - \bar{x})$ ، ومن ثم باستخدام العلاقة [3-14-b] ينتج لدينا العلاقة الآتية:

$$\hat{y} - \bar{y} = \frac{S_Y}{S_X} \mathbf{r}(x - \bar{x}) \Rightarrow \hat{y} = \bar{y} + \frac{S_Y}{S_X} \mathbf{r}(x - \bar{x}) \quad [3,19]$$

وهذه العلاقة الأخيرة هي علاقة لمستقيم يمر بالنقطة (\bar{x}, \bar{y}) ، أي إن النقطة (\bar{x}, \bar{y}) تقع على مستقيم انحدار Y على X .

الآن، وبطريقة مماثلة يمكن إثبات أن النقطة (\bar{x}, \bar{y}) تقع على مستقيم انحدار X على Y أيضاً، ومن ثم يتقاطع مستقيم انحدار Y على X مع مستقيم انحدار X على Y في النقطة (\bar{x}, \bar{y}) ، ونتيجة لذلك ستنشأ زاوية قيمتها $0 \leq \alpha \leq \frac{\pi}{2}$ (انظر الشكل السابق (٣، ١٧))، وهذه الزاوية α ذات صلة وثيقة بالارتباط بين المتغيرين X و Y ، فكلما كان الارتباط قوياً؛ صغرت قيمة زاوية التقاطع بحيث تصبح صفراً (أي إن مستقيم انحدار Y على X سيكون منطبقاً على مستقيم انحدار X على Y) عندما يصبح $\mathbf{r} = \pm 1$ وبشرط $b \neq 0$ ، وتكبر هذه الزاوية كلما ضعف الارتباط بحيث تصبح قيمتها $\frac{\pi}{2}$ (مستقيماً الانحدار متعامدان) عندما يصبح $\mathbf{r} = 0$ وبشرط $0 < S_X$ و

ولذلك فإن اقتراب أطراف مستقيمي الانحدار X على Y وكذلك Y على X من بعضهما يدل على قوة أكبر للارتباط الخطي بين المتغيرين (أو الظاهرتين) اللذين هما قيد الدراسة.

٢- من العلاقة [3,14-b] أو [3,17-b] يتضح لنا أنه يمكن تعيين معادلة مستقيم الانحدار إذا علمت قيمة معامل الارتباط r والانحراف المعياري مع المتوسطات لكل من بيانات المتغيرين X و Y .

٣- من العلاقتين [3,14-b] أو [3,17-b] نلاحظ أن حاصل ضرب معامل انحدار Y على X مع معامل انحدار X على Y يساوي قيمة معامل التحديد للمشاهدات، وذلك لأن $r \frac{S_Y}{S_X} \cdot r \frac{S_X}{S_Y} = r^2$ ، وبما $0 \leq r^2 \leq 1$ فإن ذلك يعني أنه يمكن استخدام قيمة معامل التحديد للحكم على قوة الارتباط بين البيانات، فكلما كانت قيمة هذا المعامل أقرب إلى الواحد؛ دل ذلك على قوة ارتباط أكبر بين البيانات، والعكس بالعكس صحيح.

٤- عندما يطلب من برنامج إحصائي (مثل Minitab أو SPSS) تقديم مستقيم الانحدار لبيانات معطاة فإنه يعرض لنا مستقيم انحدار Y على X فقط.

(٤، ٢، ٢، ٣) أمثلة

١- لتكن لدينا البيانات الآتية التي تمثل درجات التحصيل النهائية لعشرة طلاب في مقرر دراسي في الرياضيات:

الشكل (١٩، ٣.١)

i	المقرر X	المقرر Y
1	75	69
2	82	85
3	65	55
4	90	90
5	77	80
6	60	50
7	55	50
8	87	90
9	77	72
10	45	60

ولنقم بدراسة الارتباط والانحدار الخطي لهذه البيانات.

من أجل ذلك لدينا:

$$\sum_{i=1}^n x_i = 713 \quad \& \quad \sum_{i=1}^n x_i^2 = 52751 \quad \& \quad \sum_{i=1}^n x_i y_i = 51804$$

$$\sum_{i=1}^n y_i = 701 \quad \& \quad \sum_{i=1}^n y_i^2 = 51395 \quad \& \quad (\bar{x}, \bar{y}) = (71.3, 70.1)$$

ويفضل لتسهيل العمليات الحسابية للمقادير السابقة أن نبني الجدول الآتي:

الشكل (١٩، ٣.ب)

i	x_i	x_i^2	y_i	y_i^2	$x_i \cdot y_i$
1	75	5625	69	4761	5175
2	82	6724	85	7225	6970
3	65	4225	55	3025	3575
4	90	8100	90	8100	8100
5	77	5929	80	6400	6160
6	60	3600	50	2500	3000
7	55	3025	50	2500	2750
8	87	7569	90	8100	7830
9	77	5929	72	5184	5544
10	45	2025	60	3600	2700
sum	713	52751	701	51395	51804

ومنه تكون قيمة معامل الارتباط الخطي للبيانات المعطاة هي:

$$r_p = \frac{10 \times 51804 - 713 \times 701}{\sqrt{10 \times 52751 - 713^2} \sqrt{10 \times 51395 - 701^2}} \approx 0.8773$$

وهذا يعني وجود ارتباط خطي إيجابي قوي جداً بين بيانات المتغيرين X و Y .
أما لتعيين معادلة مستقيم انحدار Y على X فإننا نجد ما يلي:

$$b = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2} = \frac{10 \times 51804 - 713 \times 701}{10 \times 52751 - 713^2} = 0.952$$

$$a = \frac{\sum_{i=1}^n y_i \sum_{i=1}^n x_i^2 - \sum_{i=1}^n x_i \sum_{i=1}^n x_i y_i}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2} = \frac{701 \times 52751 - 713 \times 51804}{10 \times 52751 - 713^2} = 2.205$$

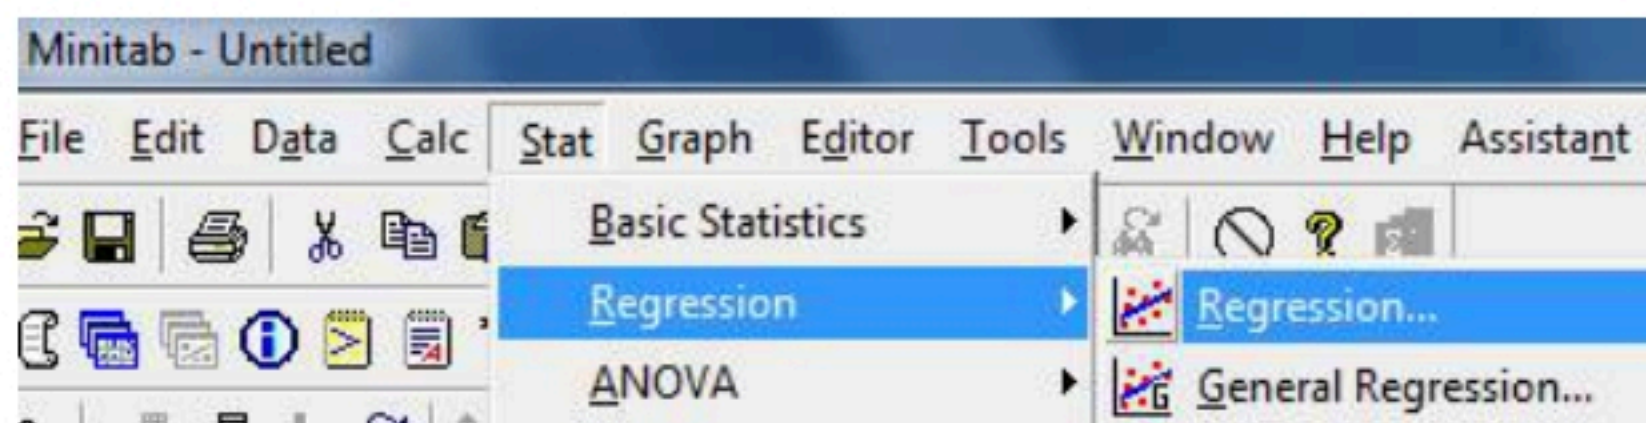
ومن ثم يكون لمعادلة مستقيم انحدار Y على X العرض الآتي:

$$\hat{Y} = 2.205 + 0.952 X$$

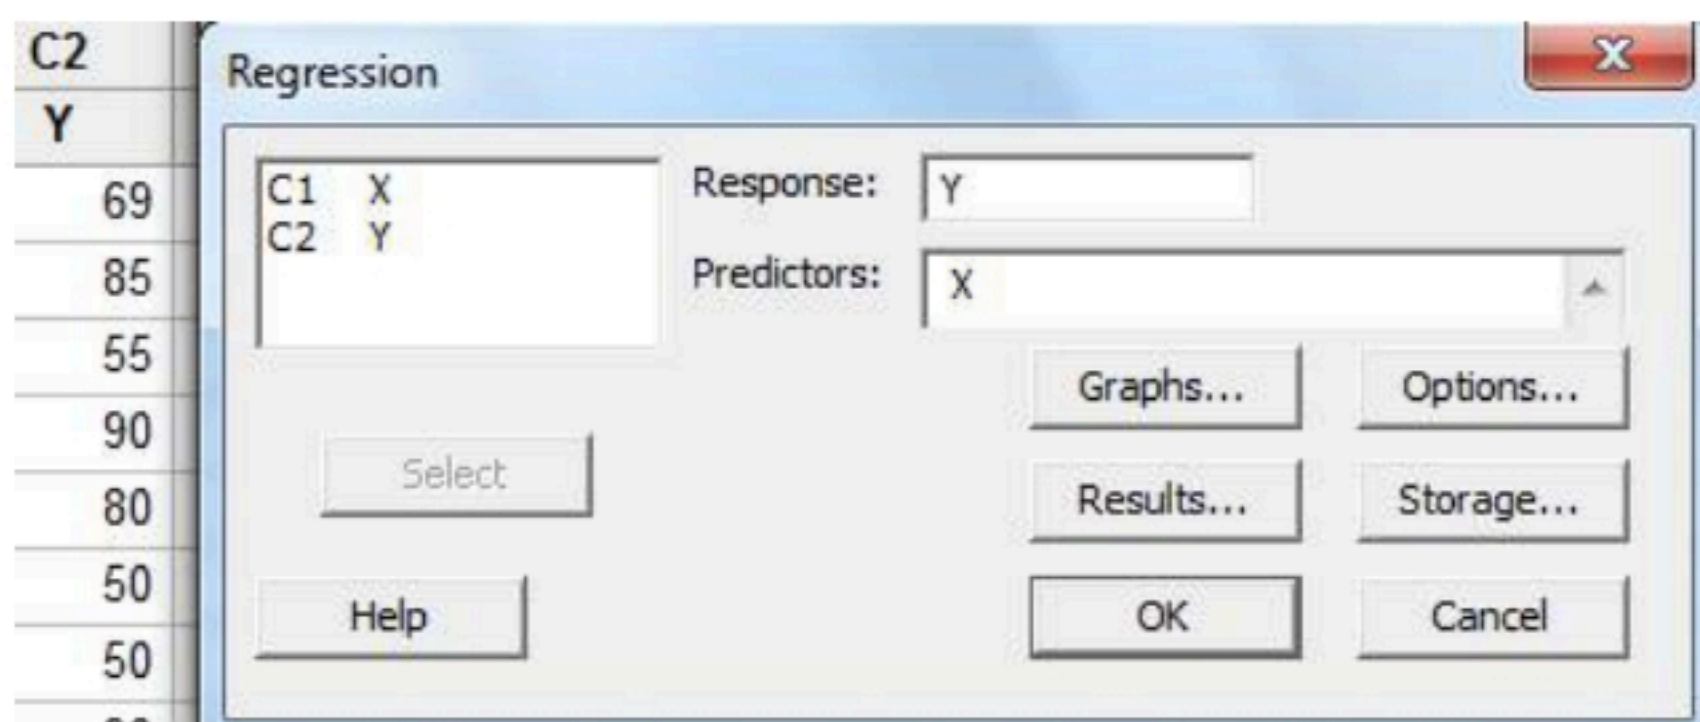
فلو أننا افترضنا أن طالباً قد حصل على الدرجة 80 في المقرر X ، فعندئذ ستكون الدرجة المقدرة له في المقرر Y هي:

$$\hat{Y} = 2.205 + 0.952(80) = 78.365 \approx 78$$

من الممكن استخدام برنامج Minitab للحصول على هذه المعادلة السابقة مع تمثيلها البياني على لوحة الانتشار وذلك باتباع الخطوات الموضحة بالصورة الآتية:



ومن ثم




فنحصل على تقرير منه المعطيات الآتية:

Regression Analysis: Y versus X

The regression equation is $Y = 2.2 + 0.952 X$ وأما الرسم البياني لمستقيم انحدار Y على X فيتم وفقاً للخطوات الآتية:Graph \Rightarrow Scatterplot \Rightarrow With Regression

فنحصل على العرض الآتي لهذا المستقيم:



الشكل (١٨، ٣.١)

وأخيراً من أجل تعيين معادلة مستقيم انحدار X على Y لدينا:

$$d = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n y_i^2 - \left(\sum_{i=1}^n y_i \right)^2} = \frac{10 \times 51804 - 713 \times 701}{10 \times 51395 - 701^2} = 0.808$$

$$c = \frac{\sum_{i=1}^n x_i \sum_{i=1}^n y_i^2 - \sum_{i=1}^n y_i \sum_{i=1}^n x_i y_i}{n \sum_{i=1}^n y_i^2 - \left(\sum_{i=1}^n y_i \right)^2} = \frac{713 \times 51395 - 701 \times 51804}{10 \times 51395 - 701^2} = 14.636$$


ومن ثم يكون لمعادلة مستقيم انحدار X على Y العرض الآتي:

$$\hat{X} = 14.636 + 0.808 Y$$

فإذا افترضنا أن طالباً قد حصل على الدرجة 66 في المقرر Y ، فعندئذ ستكون الدرجة المقدرة له في المقرر X هي:

$$\hat{X} = 14.636 + 0.808 \times 66 = 67.964 \approx 68$$

وأما التمثيل البياني لمستقيمي الانحدار للملاحظات المذكورة آنفاً سيكون لهما الشكل الآتي:



الشكل (١٨، ٣.ب).

لاحظ أن الزاوية بين مستقيمي الانحدار صغيرة نسبياً وهذا يدل على القوة الكبيرة نسبياً للارتباط بين المتغيرين Y و X .

٢- لتكن لدينا البيانات الآتية التي تمثل المبيعات الشهرية لنوعين من السلع (الأطعمة X والملابس Y) وعلى مدى عام كامل في سوق تجاري، علماً أن القيم المقدمة مقدرة بـ 10,000 وحدة نقدية.

الشكل (٢٠، ٣.أ)

i	1	2	3	4	5	6	7	8	9	10	11	12
X	13	33	100	85	16	45	75	31	42	77	36	85
Y	12	45	20	66	33	45	22	60	33	66	55	45

الآن، ولدراسة الارتباط والانحدار الخطي لهذه الملاحظات سنقوم أولاً بحساب المجاميع الآتية:

$$\sum_{i=1}^n x_i \quad \& \quad \sum_{i=1}^n x_i^2 \quad \& \quad \sum_{i=1}^n y_i \quad \& \quad \sum_{i=1}^n y_i^2 \quad \& \quad \sum_{i=1}^n x_i y_i$$

والتي سنستخدمها لتعيين قيم معامل الارتباط الخطي ومعادلة مستقيمي الانحدار، ومن أجل ذلك سننشئ الجدول الآتي لتسهيل العمليات الحسابية:

الشكل (٢٠، ٣.ب)

i	x_i	x_i^2	y_i	y_i^2	$x_i \cdot y_i$
1	13	169	12	144	156
2	33	1089	45	2025	1485
3	100	10000	20	400	2000
4	85	7225	66	4356	5610
5	16	256	33	1089	528
6	45	2025	45	2025	2025
7	75	5625	22	484	1650
8	31	961	60	3600	1860
9	42	1764	33	1089	1386
10	77	5929	66	4356	5082
11	36	1296	55	3025	1980
12	85	7225	45	2025	3825
sum	638	43564	502	24618	27587

وهكذا يكون لدينا ما يلي:


$$\sum_{i=1}^n x_i = 638 \quad \& \quad \sum_{i=1}^n x_i^2 = 43564 \quad \& \quad \sum_{i=1}^n y_i = 502 \quad \& \quad \sum_{i=1}^n y_i^2 = 24618 \quad \& \quad \sum_{i=1}^n x_i y_i = 27587$$

ومنه تكون قيمة معامل الارتباط الخطي لهذه البيانات تساوي:

$$r_p = \frac{n \cdot \left(\sum_{i=1}^n x_i y_i \right) - \left(\sum_{i=1}^n x_i \right) \cdot \left(\sum_{i=1}^n y_i \right)}{\sqrt{n \cdot \left(\sum_{i=1}^n x_i^2 \right) - \left(\sum_{i=1}^n x_i \right)^2} \cdot \sqrt{n \cdot \left(\sum_{i=1}^n y_i^2 \right) - \left(\sum_{i=1}^n y_i \right)^2}}$$

$$= \frac{12 \times 27587 - 638 \times 502}{\sqrt{12 \times 43564 - 638^2} \sqrt{12 \times 24618 - 502^2}} \approx 0.1519$$

وهذا يعني وجود ارتباط خطي إيجابي ضعيف جداً بين بيانات المتغيرين X و Y ، وهذا ما تأكدته لوحة الانتشار الآتية للبيانات المقدمة:



الشكل (١٩، ٣.أ)

وأما لتعيين مستقيم انحدار Y على X فإننا نجد:

$$b = \frac{12 \times 27587 - 638 \times 502}{12 \times 43564 - 638^2} = 0.093 \quad \& \quad a = \frac{502 \times 43564 - 638 \times 27587}{12 \times 43564 - 638^2} = 37.28$$

ومن ثم يكون لمعادلة مستقيم انحدار Y على X الصيغة $\hat{Y} = 37.28 + 0.093X$ ، فلو أننا افترضنا أن المتجر قد باع أطعمة بـ 800,000 وحدة نقدية، فعندئذ سيكون المبلغ المقدّر لبيع الملابس هو:

$$\hat{Y} = 37.28 + 0.093 \times 800000 = 74437.28$$


وأخيراً من أجل تعيين مستقيم انحدار X على Y لدينا:

$$d = \frac{10768}{43412} = 0.248 \quad \& \quad c = \frac{1857610}{43412} = 42.790$$

وبالتالي يكون لمعادلة مستقيم انحدار X على Y هذه المشاهدات الصيغة $\hat{X} = 42.790 + 0.248Y$ ، فإذا افترضنا أن المتجر قد باع ألبساً بمبلغ 100,000 فعندئذ ستكون القيمة المقدرة لمبيعات الأطعمة يساوي:

$$\hat{X} = 42.790 + 0.248 \times 100000 = 24842.79$$

وأما التمثيل البياني لمستقيمي الانحدار للمشاهدات المذكورة آنفاً سيكون لهما الشكل الآتي:



الشكل (١٩، ٣. ب).

لاحظ كبر الزاوية بين مستقيمي الانحدار، وهي تشير إلى الضعف الشديد في الارتباط بين مبيعات الملابس والأطعمة.

(٣، ٢، ٣) معادلتا مستقيمي الانحدار لبيانات مجتمع إحصائي Equations of Straights Regression for Population Data

عادة لدى البحث في معادلة مستقيم الانحدار لبيانات مجتمع إحصائي ينطلق المرء من الفرض أن حجم المجتمع غير منته أو كبير جداً، فإن كان حجم المجتمع الإحصائي منتهياً ويساوي N ، فعندئذ بفرض أن $(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$ هي بيانات هذا المجتمع والنتيجة عن إخضاع عناصره لمتغيرين X و Y ، فإنه يتم تعيين معادلة مستقيم الانحدار لبيانات هذا المجتمع كما في حالة العينات (وكان المجتمع هنا هو عينة كبيرة الحجم)، ولهذا السبب تقوم معظم البرامج الإحصائية التي تحتوي على فقرة تحليل الانحدار بالتعامل مع البيانات المقدمة على أنها بيانات عينة، ومن ثم تقدم معادلة انحدار Y على X من أجل العينات فقط.

أما إذا كان حجم المجتمع غير منته، فعندئذ لتعيين النموذج الرياضي لمعادلة مستقيم الانحدار سنحتاج إلى معارف من نظرية الاحتمالات (سنأتي على دراسة الاحتمالات في فصول قادمة)، ولكن سنقدم عرضاً موجزاً لهذه المسألة حيث سنناقش تعيين مستقيم انحدار Y على X وكذلك مستقيم انحدار X على Y .

(١, ٢, ٣) معادلة مستقيم انحدار Y على X :

إنَّ لمعادلة مستقيم انحدار Y على X لمجتمع إحصائي لها العرض الآتي:

$$\hat{Y} = \alpha + \beta X + \varepsilon \quad [3,20-a]$$

علماً أنَّ α (تمثل قيمة تقاطع مستقيم الانحدار مع المحور Y) و β (تمثل قيمة الميل لهذا المستقيم) هما ثابتان حقيقيان يُطلب تعيينهما، ويُدعى ε معلّمي مستقيم الانحدار. أما ε فإنه يُدعى **مركبة الخطأ العشوائي** Random Error Component وله خصائص محدّدة يجب أن يستوفيها (هذه الخصائص تتعلق باستقلال الأخطاء وتوزيعها الاحتمالي، ولهذا لن نخوض في تفاصيلها). الآن، ومن أجل x_i قيمة محدّدة لـ X فإنَّ قيمة \hat{y}_i المقدّرة لـ y_i تُحسب وفقاً للصيغة الآتية:

$$\hat{y}_i = \alpha + \beta x_i + \varepsilon_i \quad [3,20-b]$$


ومن ثمَّ الأخطاء $\varepsilon_i = y_i - \hat{y}_i$ من أجل كل i هي قيم عشوائية، وبما أنَّ y_i قيم ثابتة فإنَّ القيم \hat{y}_i ستصبح قيماً عشوائية أيضاً، وهكذا نلاحظ أنَّ معادلة مستقيم الانحدار للمجتمع يمكن أن تُجزأ إلى مجموع مركبتين هما:

$$\hat{Y} = \underbrace{\alpha + \beta X}_{\text{Systematic Component}} + \underbrace{\varepsilon}_{\text{Random Error Component}}$$

١- المركبة $\tilde{Y} := \hat{\alpha} + \hat{\beta}X$ ، وهي مركبة غير عشوائية تُدعى **المركبة النظامية** (أو **الرتبية**) Systematic Component حيث لدينا في هذه الحالة $\hat{\alpha}$ هو مقدّر المعلمة α ، وأما $\hat{\beta}$ فهو مقدّر المعلمة β .

٢- المركبة ε تُدعى **المركبة العشوائية** كما ذكرنا ذلك سابقاً.

نلاحظ ممّا سبق أنَّه لتعيين معادلة هذا المستقيم فإنَّ المسألة قد آلت إلى تعيين قيم مقدّرات الوسطاء α و β لهذا المستقيم، وبحيث يكون هذا المستقيم هو أفضل مستقيم يمرّ بالنقاط الممثّلة للبيانات المعطاة (أو بالقرب منها).



الشكل (٢٠, ٣)

الآن لتقدير قيم α و β نقوم بسحب عينة عشوائية (وليكن بحجم n) من المجتمع ونخضعها للمتغيّرين X و Y ، فنحصل على البيانات (x_1, y_1) ، (x_2, y_2) ، ...، (x_n, y_n) ، ومن ثمَّ نقوم بتعيين معادلة مستقيم انحدار Y على X وفقاً لطريقة المربعات الصغرى فيكون لهذه المعادلة العرض الآتي:

$$\tilde{Y} = \hat{\alpha} + \hat{\beta}X \quad [3,21]$$

وبعد ذلك تُضاف المركبة العشوائية ε إلى النموذج فنحصل على العرض الآتي للنموذج المقدرة لمعادلة مستقيم انحدار Y على X :

$$\hat{Y} = \hat{\alpha} + \hat{\beta}X + \varepsilon \quad [3,22]$$

الآن بملاحظة الصعوبة البالغة في تعيين القيم المقدرة $\hat{\beta}$ من خلال العلاقة [3,22] (أو من خلال العرض البياني الممثل لها) فإن الدارس لا يهتم بالقيمة الدقيقة لـ $\hat{\beta}$ وإنما يلجأ إلى تعيين فترة تنتمي إليها هذه القيمة باحتمال معلوم، وهذا بدوره يقود إلى ما يُعرف باسم فترات الثقة لمستقيم الانحدار التي تقع خارج إطار هذا الفصل لاعتمادها على علم العشوائيات (نظرية الاحتمالات والإحصاء الرياضي).

(٢, ٣, ٢, ٣) معادلة مستقيم انحدار X على Y :

من خلال حوار مماثل تماماً لما سبق يكون لمعادلة مستقيم انحدار X على Y العرض الآتي:

$$\hat{X} = \gamma + \delta Y + \varepsilon \quad [3,23-a]$$

ومن أجل y_i قيمة محددة لـ Y يصبح لمعادلة هذا المستقيم العرض الآتي:

$$\hat{x}_i = \gamma + \delta y_i + \varepsilon_i \quad [3,23-b]$$

علماً أن γ (تمثل قيمة تقاطع مستقيم الانحدار مع المحور OX) و δ (تمثل قيمة الميل لهذا المستقيم) ثوابت حقيقية يُطلب تعيينها، وتدعى معالم مستقيم الانحدار، وأما ε فهي مركبة الخطأ العشوائي. ومن ثم سيكون الخطأ $\varepsilon_i = x_i - \hat{x}_i$ المرافق لتقدير قيمة x_i الموافقة لـ y_i عند استخدام معادلة المستقيم [3,23-b] هي قيم عشوائية أيضاً.

الآن، وبعد تعيين $\hat{\gamma}$ و $\hat{\delta}$ كمقدرين للمعلمتين γ و δ على الترتيب يصبح للمعادلة المقدرة لمستقيم انحدار X على Y العرض الآتي:

$$\hat{Y} = \hat{\gamma} + \hat{\delta}X + \varepsilon \quad [3,24]$$

وأما بقية الأفكار التي نوقشت في الحالة السابقة فإنها تُناقش هنا بشكل مماثل تماماً.


(٣, ٢, ٣, ٣) ملاحظة

نود التأكيد على عدم المبالغة في استخدام معادلة مستقيم الانحدار في إيجاد قيمة مقدرة \hat{y}_o موافقة لقيمة x_o كيفية، بمعنى أنه من غير المحبذ (إن لم يكن من غير الجائز في بعض الحالات) استخدام المعادلة [3,20-a] (أو المعادلة [3,23-a]) في التنبؤ بقيمة \hat{y}_o المقابلة لقيمة x_o الواقعة خارج نطاق بيانات المتغير X (وفي هذه الحالة تدعى القيمة \hat{y}_o بالقيمة المتنبأ بها لـ Y والموافقة لـ x_o)، وذلك لأنه من أجل القيم التي تكون خارج الفترة التي تقع فيها مشاهدات X قد تكون العلاقة بين قيم X و Y غير خطية، ومن ثم تصبح النتائج التي نحصل عليها كقيم مقدرة ليست صحيحة أو غير دقيقة على الأقل، والمثال الآتي يوضح لنا ذلك.

(٣, ٢, ٣, ٤) مثال

لتكن لدينا المشاهدات (x_i, y_i) مع $i \in N_{15}$ المقدمة في الجدول (١٨, ٣ أ) الآتي، ولنقم بتمثيل هذه البيانات على لوحة الانتشار ومن ثم تعيين معادلة مستقيم انحدار Y على X لهذه المشاهدات، وبعد ذلك مقارنة نتائج التنبؤ بهذا المستقيم مع المنحنى الموافق لمسار هذه البيانات.

الجدول (٢١، ٣.أ)



الشكل (٢١، ٣.أ)

فنجِد للبيانات المُعطاة العرض الانتشاري المُقدَّمة في الشكل السَّابق (٢١، ٣.أ) (حيث يُلاحظ لمسار البيانات شكل علاقة غير خطيَّة)، وأمَّا من أجل حساب الأمثال a و b في معادلة مستقيم الانحدار فإنَّنا سنقدِّم الجدول الآتي لتسهيل الحسابات:

الجدول (٢١، ٣.ب).


i	x_i	x_i^2	y_i	y_i^2	$x_i \cdot y_i$
1	75	5625	69	4761	5175
2	82	6724	85	7225	6970
3	65	4225	55	3025	3575
4	90	8100	90	8100	8100
5	77	5929	80	6400	6160
6	60	3600	50	2500	3000
7	55	3025	50	2500	2750
8	87	7569	90	8100	7830
9	91	8281	85	7225	7735
10	77	5929	72	5184	5544
11	50	2500	55	3025	2750
12	45	2025	60	3600	2700
13	95	9025	85	7225	8075
14	100	10000	75	5625	7500
15	35	1225	65	4225	2275
sum	1084	83782	1066	78720	80139

فنجِد باستخدام العلاقتين [3-14-a] و [3-15-a] أنَّ:

$$b = \frac{15 \times 80139 - 1084 \times 1066}{15 \times 83782 - 1084^2} \approx 0.57$$


$$\& \quad a = \frac{1066 \times 83782 - 1084 \times 80139}{15 \times 83782 - 1084^2} \approx 29.886$$

ومن ثمَّ يكون لمعادلة مستقيم انحدار Y على X الصيغة $\hat{Y} = 29.886 + 0.57X$ ، ورسمها البياني كما في الشكل الآتي:



الشكل (٢١، ٣.ب)

الآن لو قمنا بالبحث عن منحنى مناسب لهذه البيانات فإننا نجد باستخدام برنامج Curve Expert أن كثيرة حدود من الدرجة الخامسة تُعطينا توفيقاً جيداً للبيانات (انظر الشكل الآتي).



شكل (٢١، ٣.ج)

فلو أردنا التنبؤ بالقيمة المقابلة لـ $x_o = 110$ فإننا سنلاحظ الخطأ الكبير نسبياً بين القيمة المتنبأ بها باستخدام مستقيم الانحدار والقيمة المتنبأ بها باستخدام منحنى كثيرة الحدود من الدرجة الخامسة الراسم للمسار الحقيقي (تقريباً) للبيانات، وهكذا نخلص إلى أنه إذا كانت البيانات تتوزع على شكل علاقة غير خطية، فإننا بالتأكيد سنحصل على الخطأ المستقيم الموفق للملاحظات، ولكن هذا الخط قد لا يُعطينا نتائج ذات مغزى في عمليات التنبؤ.

(٣، ٢، ٤) دقة التقديرات Accuracy of Estimates

لقد لاحظنا أن القيم الفعلية لن تقع جميعها على خط الانحدار، بل سيقع بعضها على مسافات متفاوتة عنه، ومن ثمَّ سيوجد اختلاف بين القيم المقدرة بمعادلة مستقيم الانحدار والقيم الفعلية (المشاهدة)، ولهذا نحتاج إلى مقياس يُبين لنا بدقّة مدى ملائمة هذا المستقيم للنقاط الممثلة للبيانات.

إنَّ أحد هذه المقاييس يعتمد على تشتت القيم المشاهدة عن مستقيم الانحدار الذي يُعطينا ما يُسمى بـ **الخطأ المعياري للتقدير** Standard Error of the Estimate، والذي يُستخدم كمقياس لدرجة الدقة في تقدير القيم المقدرة (أو المتنبأ بها في مسائل التنبؤ)، وبما أنَّ الانحراف المعياري هو أفضل مقياس للتشتت لمجموعة بيانات (كما ذكرنا ذلك في فصل سابق) فإنه يمكن استخدام مقياس مكافئ له من أجل انحرافات القيم الحقيقية عن مستقيم الانحدار.

نعلم أنَّ الانحراف المعياري هو الجذر التربيعي الموجب لمتوسط مربعات انحرافات البيانات عن متوسطها، ومن ثمَّ يمكننا حساب الانحراف المعياري حول مستقيم الانحدار باستخدام الأسلوب نفسه، ولكن مع الأخذ بالحسبان أنه لدينا بيانات من نوع

مختلف (ثنائيات) وأنَّ مستقيم الانحدار هو الذي سيقوم بدور الممثل للقيم الوسطى لهذه البيانات حيث لاحظنا أنَّ ذلك يؤدي إلى ظهور صيغ قد تكون مختلفة بعض الشيء عن تلك التي للبيانات المفردة.

(١, ٢, ٣) الخطأ المعياري لتقدير مستقيم الانحدار

لتكن $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ بيانات **لعينة** أخضعت لمتغيرين X و Y . عندئذ:
١- بفرض أنَّ $\hat{Y} = a + bX$ هي معادلة مستقيم انحدار Y على X ، فإنَّ **الخطأ المعياري** لتقدير هذا المستقيم يُعرف من خلال العلاقة:

$$S_{est\hat{Y}} := \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n-2}} \quad [3,25-a]$$

علماً أنَّ \hat{y}_i هي القيمة المقدرة لـ Y والموافقة لـ x_i بوساطة مستقيم الانحدار، وأما y_i فهي القيمة الفعلية (**المشاهدة**)، ولكن بملاحظة صعوبة استخدام العلاقة السابقة لحساب الخطأ المعياري لتقدير مستقيم الانحدار، فإنه يمكن استخدام قيم المشاهدات مباشرة لحساب هذا الخطأ وذلك من خلال العلاقة الآتية:

$$S_{est\hat{Y}} = \sqrt{\frac{\sum_{i=1}^n (y_i - \bar{y})^2 - b \sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{n-2}} \quad [3,25-b]$$

مع العلم أنَّ \bar{x} هو المتوسط للبيانات x_1, x_2, \dots, x_n ، وكذلك \bar{y} هو المتوسط للبيانات y_1, y_2, \dots, y_n . أو باستخدام قيمة الانحراف المعياري S_Y ومعامل الارتباط الخطي r وذلك بوساطة العلاقة المكافئة الآتية:

$$S_{est\hat{Y}} = S_Y \sqrt{\frac{n-1}{n-2} (1-r^2)} \quad [3,25-c]$$

والتي ينتج عنها أنَّ:

$$r = \sqrt{1 - \frac{(n-2)S_{est\hat{Y}}^2}{(n-1)S_Y^2}} \quad [3,26]$$

وهذه العلاقة تبين وجود علاقة جبرية بين الارتباط والتباين حول خط الانحدار، إذ إنَّ هذه الأخيرة توضح أنَّ معامل الارتباط سيكون كبيراً إذا كان التشتت حول مستقيم الانحدار صغيراً والعكس بالعكس صحيح أيضاً.

٢- بفرض أنَّ $\hat{X} = c + dY$ هي معادلة مستقيم انحدار X على Y ، فإنَّ **الخطأ المعياري** لتقدير هذا المستقيم يُعرف من خلال العلاقة الآتية:

$$S_{est\hat{X}} := \sqrt{\frac{\sum_{i=1}^n (x_i - \hat{x}_i)^2}{n-2}} \quad [3,27-a]$$

أو باستخدام العلاقة المكافئة الآتية:

$$S_{est\hat{X}} = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2 - d \sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{n-2}} \quad [3,27-b]$$


علماً أنَّ \hat{x}_i هي القيمة المقدَّرة لـ X والموافقة لـ y_i بوساطة مستقيم انحدار X على Y ، وأما x_i فهي القيمة الفعلية المقابلة لـ y_i . كذلك يمكن حساب الخطأ المعياري لتقدير هذا المستقيم باستخدام قيمة الانحراف المعياري S_Y ومعامل الارتباط الخطي \mathbf{r} وذلك بوساطة العلاقة المكافئة الآتية:

$$S_{est \hat{X}} = S_X \sqrt{\frac{n-1}{n-2} (1 - \mathbf{r}^2)} \quad [3,27-c]$$

والتي ينتج عنها أنَّ:

$$\mathbf{r} = \sqrt{1 - \frac{(n-2)S_{est \hat{X}}^2}{(n-1)S_X^2}} \quad [3,28]$$

وهكذا نلاحظ التشابه الكبير بين معادلة الخطأ المعياري لتقدير مستقيم الانحدار ومعادلة الانحراف المعياري لبيانات مُعطاة، وذلك لأنَّ كلاهما يقيس التشتت حول قيمة متوسطة، فالأول يقيس انحرافات قيم المشاهدات عن القيم النظرية التي كان يجب أن يأخذها لو اتبعت هذه المشاهدات معادلة مستقيم الانحدار، وأما الثاني فإنه يقيس انحرافات القيم حول نقطة معينة هي المتوسط، ومن ثمَّ سيكون لكل منهما الخصائص التي للانحراف المعياري نفسها، وبناءً على ما سبق يمكن تطبيق قاعدة تشيشف التجريبية من أجل مستقيم الانحدار أيضاً بحيث إنه لو قمنا برسم خطين مستقيمين موازيين لمستقيم الانحدار (ولكن من جهتين مختلفتين ويبعدان عنه بمقدار انحرافين معيارين) لوجب وجود 75% من النقاط الممثلة للمشاهدات على الأقل ضمن هذين المستقيمين. أما إذا كانا يبعدان بمقدار ثلاثة انحرافات معيارية عن مستقيم الانحدار، فإنه يفترض وجود 89% على الأقل من النقاط الممثلة للمشاهدات ضمن هذين المستقيمين، وهكذا (انظر الشكل التوضيحي الآتي).



الشكل (٣، ٢٢)

(٣، ٢، ٤، ٢) ملاحظات:


- ١- إنَّ الخطأ المعياري لتقدير مستقيمي الانحدار $S_{est \hat{Y}}$ و $S_{est \hat{X}}$ يُدعيان متوسط مربع الخطأ Mean Squared Error أيضاً.
- ٢- من أجل مستقيم انحدار Y على X ، يُدعى المقدار:

$$TV_Y := \sum_{i=1}^n (y_i - \bar{y})^2 \quad \text{التغير الكلي Total Variation للمتغير } Y$$

$$EV_Y := \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \quad \text{التغير المُفسَّر Explained Variation للمتغير } Y$$

$$UV_Y := \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad \text{التغير غير المُفسَّر Unexplained Variation للمتغير } Y$$

كما هو واضح من هذه التسميات، فإن التغير المُفسَّر يمكن أن يُفسَّر بواسطة علاقة الانحدار (العلاقة بين X و Y)، بمعنى أن التغير المُفسَّر هو الجزء من التغير الكلي لـ Y الذي يمكن إرجاعه إلى التغير في المتغير المستقل X . أما التغير غير المُفسَّر فإنه لا يمكن تفسيره بواسطة علاقة الانحدار وإنما هو نتيجة للمصادفة أو بسبب متغيرات أخرى، وذلك لأن هذا الاختلاف يمثل مجموع مربعات المسافات الرأسية التي تمثل انحرافات القيم الحقيقية (المشاهدة) عن خط الانحدار. إذاً، فهو يقيس الجزء من التغير الكلي الذي يعود إلى عوامل أخرى غير المتغير المستقل X . أي إن التغير في المتغير المستقل X لا يُفسَّر هذا الجزء من التغير الكلي (انظر الشكل التوضيحي الآتي).



شكل (٣، ٢٣)

وهكذا يكون مجموع التغير المُفسَّر وغير المُفسَّر يساوي التغير الكلي، أي إن $TV_Y = EV_Y + UV_Y$ ، كما يمكن حساب قيمة معامل التحديد وفقاً للعلاقة الآتية:

$$r^2 = \frac{EV_Y}{TV_Y} = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad [3,28]$$

وبالمثل يكون لدينا من أجل مستقيم انحدار X على Y ما يلي:

$$\begin{aligned} TV_X &= \sum_{i=1}^n (x_i - \bar{x})^2 && \text{التغير الكلي للمتغير } X \text{ هو} \\ EV_X &= \sum_{i=1}^n (\hat{x}_i - \bar{x})^2 && \text{التغير المُفسَّر للمتغير } X \text{ هو} \\ UV_X &= \sum_{i=1}^n (x_i - \hat{x}_i)^2 && \text{التغير غير المُفسَّر للمتغير } X \text{ هو} \end{aligned}$$

٣- إذا وقعت كل المشاهدات على خط الانحدار فعندئذ سيكون $UV_Y = 0$ ، ومن ثم يصبح $TV_Y = EV_Y$ ، وهذا يعني أن كل التغير في Y يرجع إلى التغير في المتغير المستقل X . بعبارة أخرى، إن التغير في المتغير المستقل X يشرح كل التغير في Y ، وبما أن قيمة معامل الارتباط في هذه الحالة سوف يساوي الواحد تماماً، فإن قيمة معامل التحديد ستصبح مساوية الواحد أيضاً، وهذا يعني أنه يمكن استخدام قيمة معامل التحديد للحكم على جودة التوفيق لمستقيم الانحدار، فكلما كانت قيمة هذا المعامل أقرب إلى الواحد؛ دل ذلك على جودة أفضل لتوفيق البيانات بمستقيم الانحدار، والعكس بالعكس.

(٣، ٢، ٤، ٣) أمثلة

رصدت الزيادة في درجات الحرارة لآلة بعد مرور أكثر من ساعة من بدء عملها وعلى فترات زمنية متتالية، فكانت النتائج كما في الجدول الآتي:

الجدول (٢٢، ١.٣)

i	x_i	y_i	i	x_i	y_i	i	x_i	y_i
1	1.07	8.435	9	2.5	9.59	17	9.9	12.007
2	1.19	8.612	10	2.9	9.82	18	11.4	12.331
3	1.33	8.743	11	3.4	10.035	19	12.9	12.605
4	1.47	8.943	12	4.1	10.318	20	14.4	12.89
5	1.63	8.986	13	4.9	10.596	21	16.4	13.147
6	1.8	9.153	14	5.9	10.879	22	18.9	13.385
7	2	9.274	15	7.1	11.26	23	21.9	13.577
8	2.2	9.415	16	8.4	11.645			

علماً أنَّ x_i هي اللحظات الزمنية التي أخذت عندها القياسات و y_i هي قيم الزيادة في درجة الحرارة عند اللحظة x_i ، ولنقم بتعيين معادلة مستقيم المربعات الصغرى لـ Y على X مستعينين بالجدول الآتي (١٩، ٣. ب).


الجدول (٢٢، ٣. ب)

i	x_i	x_i^2	y_i	y_i^2	$x_i \cdot y_i$
1	1.07	1.1449	8.435	71.14923	9.02545
2	1.19	1.4161	8.612	74.16654	10.24828
3	1.33	1.7689	8.743	76.44005	11.62819
4	1.47	2.1609	8.943	79.97725	13.14621
5	1.63	2.6569	8.986	80.7482	14.64718
6	1.8	3.24	9.153	83.77741	16.4754
7	2	4	9.274	86.00708	18.548
8	2.2	4.84	9.415	88.64223	20.713
9	2.5	6.25	9.59	91.9681	23.975
10	2.9	8.41	9.82	96.4324	28.478
11	3.4	11.56	10.035	100.7012	34.119
12	4.1	16.81	10.318	106.4611	42.3038
13	4.9	24.01	10.596	112.2752	51.9204
14	5.9	34.81	10.879	118.3526	64.1861
15	7.1	50.41	11.26	126.7876	79.946
16	8.4	70.56	11.645	135.606	97.818
17	9.9	98.01	12.007	144.168	118.8693
18	11.4	129.96	12.331	152.0536	140.5734
19	12.9	166.41	12.605	158.886	162.6045
20	14.4	207.36	12.89	166.1521	185.616
21	16.4	268.96	13.147	172.8436	215.6108
22	18.9	357.21	13.385	179.1582	252.9765
23	21.9	479.61	13.577	184.3349	297.3363
sum	157.69	1951.568	245.646	2687.089	1910.765

فوجد أنَّ قيم المعلمتين a و b هما $a = 8.896$ و $b = 0.26$ ، ومن ثمَّ يكون لمعادلة مستقيم انحدار Y على X العلاقة الآتية:

$$\hat{Y} = 8.896 + 0.26X$$

ولتمثيلها البياني الشكل الآتي:



الشكل (٢٤، ٣)

ومن أجل حساب الخطأ المعياري للتقدير فإنه لدينا:

الجدول (٢٢، ٣.ج)

i	x_i	y_i	ε_i	\hat{y}_i	$(y_i - \bar{y})^2$	$(\hat{y}_i - \bar{y})^2$	$(y_i - \hat{y}_i)^2$
1	1.07	8.435	-0.739	9.174002	5.040025	2.268031	0.546123
2	1.19	8.612	-0.59324	9.20524	4.276624	2.174916	0.351934
3	1.33	8.743	-0.49869	9.241686	3.751969	2.068747	0.248688
4	1.47	8.943	-0.33513	9.278131	3.017169	1.965236	0.112313
5	1.63	8.986	-0.33378	9.319783	2.869636	1.85019	0.111411
6	1.8	9.153	-0.21104	9.364038	2.331729	1.731755	0.044537
7	2	9.274	-0.1421	9.416103	1.976836	1.597435	0.020193
8	2.2	9.415	-0.05317	9.468168	1.600225	1.468537	0.002827
9	2.5	9.59	0.043735	9.546265	1.1881	1.285354	0.001913
10	2.9	9.82	0.169605	9.650395	0.7396	1.060086	0.028766
11	3.4	10.035	0.254443	9.780557	0.416025	0.808997	0.064741
12	4.1	10.318	0.355216	9.962784	0.131044	0.514398	0.126178
13	4.9	10.596	0.424956	10.17104	0.007056	0.259036	0.180588
14	5.9	10.879	0.447632	10.43137	0.039601	0.061818	0.200374
15	7.1	11.26	0.516243	10.74376	0.3364	0.004065	0.266506
16	8.4	11.645	0.562821	11.08218	0.931225	0.161748	0.316767
17	9.9	12.007	0.534334	11.47267	1.760929	0.628319	0.285513
18	11.4	12.331	0.467848	11.86315	2.725801	1.399849	0.218882
19	12.9	12.605	0.351361	12.25364	3.705625	2.476338	0.123455
20	14.4	12.89	0.245875	12.64413	4.8841	3.857787	0.060454
21	16.4	13.147	-0.01777	13.16477	6.086089	6.174101	0.000316
22	18.9	13.385	-0.43058	13.81558	7.317025	9.831891	0.185403
23	21.9	13.577	-1.01956	14.59656	8.392609	15.33942	1.039498
sum	157.69	245.646	5.4E-10	245.646	63.52544	58.98806	4.537382

حيث نجد من معطيات الجدول السابق ما يلي:

$$\mathbf{TV}_Y = \sum_{i=1}^n (y_i - \bar{y})^2 = 63.52544 \quad \text{- التغير الكلي للمتغير } Y \text{ يساوي}$$

$$\mathbf{EV}_Y = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 = 58.98806 \quad \text{- التغير المُفسر للمتغير } Y \text{ يساوي}$$

$$\mathbf{UV}_Y = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = 4.537382 \quad \text{- التغير غير المُفسر للمتغير } Y \text{ يساوي}$$

وهكذا يكون لدينا:

$$\mathbf{EV}_Y + \mathbf{UV}_Y = 58.98806 + 4.537382 = 63.52544 = \mathbf{TV}_Y$$

ومن جهة أخرى نجد أن الخطأ المعياري لتقدير مستقيم الانحدار يساوي:

$$S_{est\hat{Y}} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n-2}} = \sqrt{\frac{4.53738}{23-2}} = 0.46483$$

وبحساب قيمة الانحراف المعياري $S_Y = 1.69927$ نجد أن قيمة معامل التحديد \mathbf{r}^2 تساوي:

$$\mathbf{r}^2 = 1 - \frac{(n-2)S_{est\hat{Y}}^2}{(n-1)S_Y^2} = 1 - \frac{21 \times 0.2161}{22 \times 2.88752} = 0.92857$$

أو باستخدام العلاقة [3,28] يكون لدينا:

$$\mathbf{r}^2 = \frac{\mathbf{EV}_Y}{\mathbf{TV}_Y} = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = \frac{58.98806}{63.52544} = 0.92857$$

إن العلاقة الأخيرة توضح لنا أن 93% من أسباب الزيادة في ارتفاع الحرارة تعود لطول فترة تشغيل الآلة، وأكثر من ذلك نلاحظ أن $\mathbf{r} = 0.9636$ التي تثبت وجود ارتباط قوي جداً بين ازدياد درجة الحرارة وطول الفترة الزمنية التي تعمل بها الآلة.

الآن، وبإمعان النظر في الشكل (٣, ٢٤) فإننا نلاحظ أن خط الانحدار الأنسب للبيانات هو خط منحن وليس مستقيماً، ومعادلة ذلك المنحنى تُدعى **نموذج ويبول** Weibull Model للانحدار (نسبة إلى المهندس والرياضياتي السويدي **Ernst Hjalmar Waloddi Weibull (1887-1979)**)، ومعادلته من الشكل:

$$\hat{Y} = 16269 - 9.5658 \exp[-20.3712X^{60.1963}]$$

وبخطاً معياري يساوي $S_{est\hat{Y}} = 0.0602$ ، وهذا يعني أن توفيق هذه البيانات بهذه المعادلة ممتازاً، وأما معامل التحديد الموافق لهذا المنحنى فإنه يساوي $\mathbf{r}^2 = 0.998$ الذي يوضح لنا أن 99.89% من أسباب الزيادة في ارتفاع حرارة الآلة تعود لطول فترة تشغيل هذه الآلة.

لكن لماذا تناولنا هذا الحوار وقد أكدنا سابقاً بأننا سنهتم بالنماذج الخطية فقط؟

في الحقيقة توجد حالات يكون فيها الحصول على منحنى لتوفيق انحدار البيانات ممكناً من خلال استخدام تقنية الانحدار الخطي، ومن ثم نحصل على خط انحدار أفضل (أي بخطأ معياري أقل) وهو بدوره يقدم لنا تقديرات أكثر دقة من مستقيم الانحدار، والفقرة التالية تقدم لنا عرضاً موجزاً حول هذا الموضوع.

(٣,٣) الانحدار غير الخطي وتوفيق المنحنيات

Nonlinear Regression and Curves Fitting

لقد لاحظنا في أمثلة سابقة أنه قد تكون طبيعة العلاقة بين المتغيرين X و Y غير خطية، ومن ثم يكون استخدام مستقيم الانحدار لتقدير قيم المشاهدات غير مجسبب كـ \bar{Y} الخطأ المعياري الذي سيرافقه، وذلك لأنه قد يكون قسم كبير من النقاط الممثلة للمشاهدات متناثرة بعيداً نسبياً عن مستقيم الانحدار (انظر الشكل التوضيحي (٣,٢١ ب.))، ولذلك فإن محاولة تمهيد الخط البياني (إن أمكن ذلك) الممثل للعلاقة المتوسطة بين المتغيرين سيكون أكثر نفعاً وفائدة، ومن ثم تصبح الفروق ما بين القيم المشاهدة والقيم المقدرة لها صغيرة نسبياً، وهذا بدوره يجعل قيمة معامل الارتباط (ومن ثم قيمة معامل التحديد) أكبر بكثير من تلك التي لمستقيم الانحدار. لهذا السبب كنا منذ البدء حذرين في تفسير النتائج المترتبة على قيمة معامل الارتباط.

الآن لنفترض أن لدينا بيانات على شكل ثنائيات (أزواج) ناتجة عن دراسة متغيرين X و Y (ممثلين لظاهرتين)، فعندئذ من أجل بعض الحالات الخاصة يمكننا رد العلاقات غير الخطية للانحدار إلى شكل خطي من خلال استخدام تحويلات مناسبة للبيانات، ومن ثم دراسة البيانات الناتجة عن التحويل وفقاً للانحدار الخطي، وبعد ذلك العودة إلى العلاقة الأصل باستخدام التحويلات العكسية للعلاقات التي استخدمت في البدء. لكن قبل البدء بتقديم بعض هذه الحالات الخاصة سنقوم بتوضيح عملية الخطية لعلاقة (ممكنة التحويل) وذلك باستخدام المثال السابق (٣, ٢, ٤, ٣) حيث وجدنا أن البيانات المعطاة تمتلك انحداراً من نموذج ويبول، ومعادلته كانت من الشكل الآتي:

$$Y = 16269 - 9.5658 \exp[-20.3712 X^{60.1963}] \quad (*)$$

ولنشاهد ما الذي سيحدث للبيانات بعد استخدام التحويلات اللازمة لعملية الخطية. بملاحظ أنه يمكننا كتابة العلاقة السابقة (*) على النحو الآتي:

$$\ln \left[\frac{Y - 16269}{-9.5658} \right] = -20.3712 X^{60.1963}$$

والتي تكتب بالشكل الآتي أيضاً:

$$\ln \ln \left[\frac{Y - 16269}{-9.5658} \right]^{-1} = \ln 20.3712 + 60.1963 \ln X$$

وينتج عنها أنه من أجل كل $i \in N_{23}$ سيكون لدينا:

$$\ln \ln \left[\frac{y_i - 16269}{-9.5658} \right]^{-1} = \ln 20.3712 + 60.1963 \ln x_i$$

والآن لنضع $b = 60.1963$ ، ولنستخدم التحويلات:

$$Y^* := \ln \ln \left[\frac{Y - 16269}{-9.5658} \right]^{-1}$$

$$a^* := \ln 20.3712$$

$$X^* := \ln X$$

فيصبح للعلاقة السابقة (*) العرض:


$$Y^* = a^* + b X^*$$

وهي علاقة خطية بـ X^* ، والجدول الآتي يدون قيم x_i^* و y_i^* .

الجدول (٢٢، ٣.د)

i	x_i	y_i	x_i^*	y_i^*
1	1.07	8.435	0.068	-2.00664285
2	1.19	8.612	0.174	-2.00664139
3	1.33	8.743	0.285	-2.0066403
4	1.47	8.943	0.385	-2.00663865
5	1.63	8.986	0.489	-2.0066383
6	1.8	9.153	0.588	-2.00663692
7	2	9.274	0.693	-2.00663591
8	2.2	9.415	0.788	-2.00663475
9	2.5	9.59	0.916	-2.0066333
10	2.9	9.82	1.065	-2.0066314
11	3.4	10.035	1.224	-2.00662962
12	4.1	10.318	1.411	-2.00662728
13	4.9	10.596	1.589	-2.00662498
14	5.9	10.879	1.775	-2.00662264
15	7.1	11.26	1.96	-2.00661949
16	8.4	11.645	2.128	-2.00661631
17	9.9	12.007	2.293	-2.00661332
18	11.4	12.331	2.434	-2.00661064
19	12.9	12.605	2.557	-2.00660837
20	14.4	12.89	2.667	-2.00660601
21	16.4	13.147	2.797	-2.00660389
22	18.9	13.385	2.939	-2.00660192
23	21.9	13.577	3.086	-2.00660033

والآن لو نظرنا إلى العرض الانتشاري لهذه النقاط (x_i^*, y_i^*) مع $i \in N_{23}$ ، فإننا سنلاحظ كيف أصبح شكل توزيع البيانات وكأنها واقعة على خط مستقيم واحد، وهذا هو التفسير الهندسي لمذلول خطية علاقة ما (أي تحويلها إلى علاقة خطية).



شكل (٢٥، ٣)

(١, ٣, ٣) نماذج انحدار يمكن ردها إلى خطية


فيما يلي نقدم بعض العلاقات البسيطة والشهيرة التي يمكن خطيتها، ونبدؤها بالانحدار الكسري البسيط (أو التناظري):

(١, ١, ٣) الانحدار الكسري البسيط Simple Fractional Regression


في هذا النوع من الانحدار تكون العلاقة التي تربط بين المتغيرين X و Y من الشكل الآتي:

$$Y = \frac{1}{a+bX} \quad ; a, b \in \mathbb{R}, b \neq 0 \quad [3,30]$$

نلاحظ هنا أن الدالة المعطاة بالعلاقة السابقة هي علاقة دالة كسرية بسيطة (أو تناظرية)، ولذلك فإن الانحدار الذي يستخدم هذه العلاقة يُسمى **انحداراً كسرياً بسيطاً** (انظر الأشكال التوضيحية الآتية).



الشكل (٢٦, ٣. ب)



الشكل (٢٦, ٣. أ)

فعندئذ من أجل خطية هذه العلاقة نقوم باستخدام التحويل:

$$y_i^* = \frac{1}{y_i} \quad ; i = 1, 2, \dots, n$$

ومن ثم يكون لعلاقة الانحدار الشكل الخطي الآتي:

$$Y^* = a + bX \quad ; a, b \in \mathbb{R}, b \neq 0$$

وبعد ذلك نقوم بحساب الثوابت a و b بطريقة المربعات الصغرى بناءً على البيانات بعد عملية التحويل، أي يجب الأخذ بالحسبان أن القيم لـ Y^* التي سنعوّض بها في العلاقات لتعيين a و b هي $y_i^* = \frac{1}{y_i}$ مع $N_n \ni i$ ، ومن ثم التعويض في العلاقة السابقة، وبعد ذلك العودة إلى العلاقة الأصل من خلال وضع:

$$\hat{Y} = \frac{1}{Y^*} = \frac{1}{a+bX} \quad ; a, b \in \mathbb{R}, b \neq 0$$


فنكون بذلك قد عينا علاقة منحنى الانحدار.

(٢, ١, ٣) الانحدار اللوغاريتمي Logarithmic Regression

في هذا النوع من الانحدار تكون العلاقة التي تربط بين المتغيرين X و Y من الشكل الآتي:

$$Y = a + b \ln X \quad ; X > 0 \text{ \& } a, b \in \mathbb{R}, b \neq 0 \quad [3,31]$$

لاحظ أن الدالة المعطاة بالعلاقة السابقة هي علاقة دالة لوجارتمية، ولذلك فإن الانحدار الذي يستخدم هذه العلاقة يُسمى الانحدار اللوغارتمي (انظر الشكل الآتي لبيانات تتوزع وفقاً للعلاقة [3,31]).



الشكل (٣، ٢٧)

وفي هذه الحالة نستخدم التحويل $X^* = \ln X$ فتصبح لدينا العلاقة:

$$Y = a + b X^* ; a, b \in \mathbb{R}, b \neq 0$$

وبعد ذلك نقوم بتعيين قيم الثوابت a و b بطريقة المربعات الصغرى على أن نأخذ بالحسبان أن القيم X^* التي سنعوض بها في العلاقات لتعيين a و b هي $\ln x_i$ لكل $i \in \mathbb{N}_n$ ، وبعد ذلك نعوض لنحصل على العلاقة:


$$\hat{Y} = a + b \ln X ; X > 0 \text{ \& } a, b \in \mathbb{R}, b \neq 0$$

(٣، ٣، ١، ٣) الانحدار الأسّي Exponential Regression

في هذا النوع من الانحدار تكون العلاقة التي تربط بين المتغيرين X و Y من الشكل الآتي:

$$Y = a e^{bX} ; a, b \in \mathbb{R}, b \neq 0 \quad [3,32]$$

فلاحظ أن الدالة المعطاة بالعلاقة السابقة هي علاقة لدالة أسية، ولذلك فإن الانحدار الذي يستخدم هذه العلاقة يُسمى الانحدار الأسّي (انظر الشكل الآتي لبيانات تتوزع وفقاً للعلاقة [3,32]).



الشكل (٣، ٢٨)

في هذه الحالة نقوم برّد هذا الشكل إلى شكل خطي من خلال أخذ اللوغاريتم لطرفي العلاقة السابقة فيصبح لها العرض الآتي:

$$\ln Y = \ln a + b X$$

ومن ثم نستخدم التحويلين $a^* = \ln a$ و $Y^* = \ln Y$ ، فيكون لدينا علاقة خطية من الشكل:

$$Y^* = a^* + b X$$

وبعد ذلك نقوم بتعيين قيم الثوابت a^* و b بوساطة طريقة المربعات الصغرى بناءً على البيانات بعد عملية التحويل، ومن ثم نقوم بالتعويض في العلاقة الأخيرة، وبعد ذلك العودة إلى الشكل الأصل باستخدام العلاقات العكسية فنحصل على تقدير Y من خلال العلاقة:

$$\hat{Y} = e^{Y^*} = e^{a^* + bX} = e^{\ln a} e^{bX} = a e^{bX}$$

Power Regression (٣, ٣, ١, ٤) انحدار القوى

إذا كانت علاقة الانحدار التي تربط بين المتغيرين X و Y من الشكل:

$$Y = aX^b \quad ; \quad X > 0 \text{ \& } a > 0, \quad b \in \mathbb{Q} \quad [3,33]$$

وهذا النوع من الانحدار يُدعى **انحدار القوى** لأنَّ الدالة المُعطاة بالعلاقة السابقة هي علاقة لدالة قوى بـ X (انظر الأشكال الآتية) التي يمكن تحويلها إلى نموذج خطي من خلال أخذ اللوغاريتم لطرفي العلاقة السابقة، فنحصل على العلاقة:

$$\ln Y = \ln a + b \ln X$$

ومن ثمَّ نستخدم التحويلات:


$$Y^* = \ln Y \quad \& \quad a^* = \ln a \quad \& \quad X^* = \ln X$$

فيصبح لدينا:


$$Y^* = a^* + b X^*$$

وبعد ذلك نقوم بتقدير a^* و b بطريقة المربعات الصغرى، ومن ثمَّ التعويض في العلاقة الأخيرة بناءً على البيانات بعد عملية التحويل، ومن ثمَّ التعويض في العلاقة السابقة، وبعد ذلك العودة إلى الشكل الأصل باستخدام العلاقات العكسية فنحصل على تقدير من خلال:


$$\hat{Y} = e^{Y^*} = e^{a^* + b X^*} = e^{a^*} e^{b X^*} = e^{\ln a} e^{b \ln X} = a X^b$$




الشكل (٢٩, ٣, ب)



الشكل (٢٩, ٣, أ)



الشكل (٣٠, ٣, د)



الشكل (٣٠, ٣, ج)

(٣, ٣, ٢) نماذج لا يمكن خطيتها

لقد ذكرنا فيما سبق بأنه يمكن ردّ بعض علاقات الانحدار غير الخطية إلى نماذج خطية، ومن ثمّ دراستها كما هو الحال لدى الانحدار الخطي لتقدير الثوابت a و b في معادلة الانحدار، ولكن هناك علاقات كثيرة لا يمكن ردّها إلى شكل خطي منها على سبيل المثال لا الحصر كثيرات الحدود $Y = a_0 + a_1 X + a_2 X^2 + \dots + a_n X^n$ مع $n \in \mathbb{N}$ ، وكذلك العلاقات المثلثية التي من الشكل:

$$Y = a \cos bX \quad \text{or} \quad Y = a \sin bX$$

وهناك علاقات كثيرة أخرى. في مثل هذه الحالات يمكن معالجة بعض الحالات الخاصة منها بطريقة المربعات الصغرى، أو بطرائق أخرى مثل طريقة الفروق المتتالية، ولكننا لن نتطرق لمثل هذه الطرائق في هذا الفصل حيث سنقوم في فصل قادم (الفصل الثاني عشر) باستخدام طريقة الفروق المتتالية لتوفيق منحني لكثيرة حدود من الدرجة n من أجل استخدامه كتقدير للاتجاه العام لمتسلسلة زمنية.

(٣, ٤) الارتباط المتعدد والجزئي

Multiple and Partial Correlation

لقد لاحظنا أنه عندما يكون لدينا متغيرين يمكن البحث في العلاقة التي تربط بينهما من خلال حساب تباينهما كما في معامل بيرسون للارتباط الخطي، ولكن عندما يصبح عدد المتغيرات أكبر من ذلك فعندئذ يتحدث المرء عن التأثير المتبادل بين هذه المتغيرات على أوجه مختلفة، فإما أن يبحث في التأثير المتبادل بين كل هذه المتغيرات، فيكون المرء أمام ما يُعرف باسم **الارتباط المتعدد المتغيرات (أو الارتباط الكلي)**، أو أن يبحث في التأثير المتبادل بين جزء من هذه المتغيرات مع تثبيت بقية المتغيرات، فيكون المرء أمام ما يُعرف باسم **الارتباط الجزئي**. أما بالنسبة إلى التباين فيصبح لها شكل مصفوفة مربعة من مرتبة تساوي عدد المتغيرات وتُدعى **مصفوفة التباين**.

(٣, ٤, ١) الارتباط المتعدد Multiple Correlation


لقد ذكرنا سابقاً مقياساً للارتباط بين ظاهرتين فقط، إلا أن كثيراً ما تكون الظاهرة التي هي قيد الدرس متأثرة بظواهر كثيرة أخرى، فعلى سبيل المثال غالباً ما يكون سعر سلعة متأثراً بأكثر من عامل، مثل أسعار سلع أخرى، وتوفر هذه السلعة من عدمه، وإمكانية حصول المستهلك عليها، ومن ثمّ فإننا بحاجة لدراسة الارتباط بين أكثر من متغيرين كما هو ملاحظ، وعلى العموم فلو افترضنا أن لدينا n متغيراً X_1, X_2, \dots, X_n تصف n ظاهرة، وأن العلاقة التي تربط بين المتغير X_k وبقية المتغيرات هي:

$$X_k = f(X_1, X_2, \dots, X_{k-1}, X_{k+1}, \dots, X_n) \quad [3,34]$$

علماً أن هذه العلاقة قد تكون علاقة خطية من الشكل:


$$X_k = a_0 + a_1 X_1 + a_2 X_2 + \dots + a_{k-1} X_{k-1} + a_{k+1} X_{k+1} + \dots + a_n X_n$$

فعلى سبيل المثال لو كان لدينا ثلاثة متغيرات فقط، وكانت العلاقة الخطية بينها من الشكل $X_3 = 15 - 3X_1 + 4X_2$ ، فعندئذ سيكون تمثيل قيم هذه المتغيرات في الفضاء ثلاثي الأبعاد هي نقاط تقع على أو بالقرب من سطح مستو كما في الشكل الآتي:



M

الشكل (٣, ٣١) ب)




M

الشكل (٣, ٣١) أ)

ولكن قد تكون العلاقة [3,34] غير خطية، فعلى سبيل المثال لو كان لدينا ثلاثة متغيرات فقط، وكانت العلاقة بينها من الشكل:


$$X_3 = 5 - 3X_1^2 + 5X_2$$

فعندئذ سيكون تمثيل قيم هذه المتغيرات في الفضاء ثلاثي الأبعاد هي نقاط تقع على أو بالقرب من سطح مقوس كما في الشكل الآتي:



M

الشكل (٣، ٣٢) أ.



M

الشكل (٣، ٣٢) ب.

وهنا يلاحظ إمكانية قياس الارتباط بين X_k وكل المتغيرات الأخرى مجتمعة (أي تلك المتغيرات التي تتغير كلها في وقت واحد) وذلك باستخدام أحد مقاييس الارتباط المتعدد.

الآن لتوضيح ما سبق سنقوم بدراسة الحالة البسيطة المتمثلة بالارتباط المتعدد الخطي وذلك عندما يكون لدينا ثلاثة متغيرات X, Y, Z فقط، وأن المشاهدات الناتجة عن هذه المتغيرات هي $(x_1, y_1, z_1), (x_2, y_2, z_2), \dots, (x_n, y_n, z_n)$ ، وأنه لدينا:

$$Z = a + bX + cY \quad [3,35]$$

علماً أن a, b, c في العلاقة [3-35] هي ثوابت يُطلب تقديرها حتى يمكننا النظر إلى السطح الممثل بالعلاقة [3-35] كأفضل توفيق للمشاهدات (x_i, y_i, z_i) من أجل كل $i \in N_n$.

إن المبادئ العامة للارتباط المتعدد هي نفسها كما هو الحال لدى الارتباط البسيط، إذ يمكننا استخدام طريقة المربعات الصغرى لكي نوفق سطحاً يصف العلاقة المتوسطة بين المتغيرات التي هي قيد الدراسة، وبحيث يكون مجموع انحرافات المشاهدات عن هذا السطح يساوي الصفر، وكذلك مجموع مربعات تلك الانحرافات عن ذلك السطح أقل ما يمكن. بعبارة أخرى، إن المبادئ التي تُستخدم فيها طريقة المربعات الصغرى لدى توفيق خط يصف العلاقة المتوسطة بين متغيرين تنطبق على حالتنا هذه أيضاً، ولكن الفارق هو أن لدينا في هذه الحالة ثلاثة محاور ونحاول توفيق سطح بين تلك المشاهدات بحيث يُحقق الشروط السابقة نفسها.

والآن لتقدير الثوابت a, b, c وفقاً لطريقة المربعات الصغرى نحصل على العلاقات الآتية:

$$\left. \begin{aligned} \sum_{i=1}^n z_i &= a \cdot n + b \sum_{i=1}^n x_i + c \sum_{i=1}^n y_i \\ \sum_{i=1}^n x_i z_i &= a \sum_{i=1}^n x_i + b \sum_{i=1}^n x_i^2 + c \sum_{i=1}^n x_i y_i \\ \sum_{i=1}^n y_i z_i &= a \sum_{i=1}^n y_i + b \sum_{i=1}^n x_i y_i + c \sum_{i=1}^n y_i^2 \end{aligned} \right\} \quad [3,36]$$

وبالحل المشترك لجملة المعادلات [3-36] نحصل على قيم الثوابت a, b, c ، ومن ثم التعويض في العلاقة السابقة [3-36] نحصل على العلاقة التي تقدّر لنا قيمة Z لدى تغير قيمة X و Y معاً، وهذه العلاقة تُكتب بالشكل الآتي:

$$\hat{Z} = a + bX + cY$$

الجدول (٢٣، ٣.أ)

i	x_i	y_i	z_i	i	x_i	y_i	z_i
1	0	21	15	9	2	25	30
2	0	18	15	10	2	38	45
3	0	22	21	11	3	44	50
4	1	24	28	12	3	51	60
5	1	25	30	13	4	39	45
6	1	25	35	14	4	54	60
7	1	26	40	15	5	55	50
8	2	34	35				

ولنفترض أننا نرغب بتعيين العلاقة الخطية التي تربط بين نتائج اختبار مقرر الإحصاء وكل من نتائج مقرر الرياضيات والمدة الزمنية التي أمضاها لدراسة هذين المقررين. في هذه الحالة ستكون العلاقة بين هذه المتغيرات من الشكل:

$$Z = a + b X + c Y \tag{1}$$

ولكن لتقدير الأمثال a, b, c علينا حساب المجاميع المعطاة بالعلاقات [3-36] من أجل $n = 15$ ، حيث لدينا:

الجدول (٢٣، ٣.ب)

i	x_i	y_i	z_i	$x_i \cdot y_i$	$x_i \cdot z_i$	$y_i \cdot z_i$	x_i^2	y_i^2	z_i^2
1	0	21	15	0	0	315	0	441	225
2	0	18	15	0	0	270	0	324	225
3	0	22	21	0	0	462	0	484	441
4	1	24	28	24	28	672	1	576	784
5	1	25	30	25	30	750	1	625	900
6	1	25	35	25	35	875	1	625	1225
7	1	26	40	26	40	1040	1	676	1600
8	2	34	35	38	70	1190	4	1156	1225
9	2	25	30	50	60	750	4	625	900
10	2	38	45	76	90	1710	4	1444	2025
11	3	44	50	132	150	2200	9	1936	2500
12	3	51	60	153	180	3060	9	2601	3600
13	4	39	45	156	180	1755	16	1521	2025
14	4	54	60	216	240	3240	16	2916	3600
15	5	55	50	275	250	2750	25	3025	2500
sum	29	501	559	1226	1353	21039	91	18975	23775

وبعد التعويض عن قيم المجاميع في المعادلات [3-36] كل بما يساويه من الجدول السابق (٢٣، ٣.ب) نحصل على جملة المعادلات الخطية الآتية:

$$\left. \begin{aligned} 559 &= 15 a + 29 b + 501 c \\ 21039 &= 29 a + 91 b + 1226 c \\ 21039 &= 501 a + 1226 b + 18975 c \end{aligned} \right\} \tag{2}$$

وبحل جملة المعادلات (2) نجد أن مقدرات الأمثال a, b, c هي $a = 2.08$ ، $b = 0.06$ و $c = 1.05$ على الترتيب، ومن ثم ستكون لعلاقة الارتباط (1) العرض الآتي:

$$\hat{Z} = 2.08 + 0.06 X + 1.05 Y$$

ومن أجل الحصول على قيمة معامل الارتباط المتعدد سنقوم أولاً بحساب الخطأ المعياري للتقدير حيث لدينا:

$$\hat{z}_i = 2.08 + 0.06 x_i + 1.05 y_i$$

ومنه يكون:

الجدول (٢٣، ٣.ج)

i	z_i	\hat{z}_i	$(z_i - \hat{z}_i)^2$	i	z_i	\hat{z}_i	$(z_i - \hat{z}_i)^2$
1	15	24.13	83.3569	9	30	28.45	2.4025
2	15	20.98	35.7604	10	45	42.1	8.41
3	21	25.18	17.4724	11	50	48.46	2.3716
4	28	27.34	0.4356	12	60	55.81	17.5561
5	30	28.39	2.5921	13	45	43.27	2.9929
6	35	28.39	43.6921	14	60	59.02	0.9604
7	40	29.44	111.5136	15	50	60.13	102.6169
8	35	37.9	8.41	sum	559	558.99	440.5435


وبحسب العلاقة [3-37] تكون قيمة الخطأ المعياري للتقدير تساوي:

$$S_{est \hat{Z}} = \sqrt{\frac{1}{n-2} \sum_{i=1}^n (z_i - \hat{z}_i)^2} = \sqrt{\frac{440.5435}{13}} = 5.821$$


ومن ثم تكون قيمة معامل الارتباط المتعدد هي:

$$r_{Z;XY} = \sqrt{1 - \frac{S_{est \hat{Z}}^2}{S_Z^2}} = \sqrt{1 - \frac{33.888}{210.2095}} = 0.839$$

وهذا يعني وجود ارتباط قوي جداً بين نتائج اختبار مقرر الإحصاء من جانب وتمكن الطالب في الرياضيات مع المدة التي يمضيها في دراسة هذين المقررين. انظر الشكل الآتي الذي يبين المستوى الموفق للملاحظات والتوضع النسبي للنقاط الممثلة للملاحظات مع هذا المستوى.



الشكل (٣٣، ٣.ب)



الشكل (٣٣، ٣.أ)

(٣, ٤, ١, ٣) ملاحظة

نلاحظ مما سبق أنَّ هذه الطريقة تعطي طريقة عامة لحساب قيمة معامل الارتباط المتعدد، وحتى في حال أصبح عدد المتغيرات المستقلة أكثر من ثلاثة، فإنه يُبحث في تقدير الثوابت التي تحدّد لنا أفضل شكل ممثّل للعلاقة المتوسطة بين المشاهدات، ومن ثمّ حساب الخطأ المعياري مع أخذ المتغير الجديد في الحسبان لدى حساب الخطأ المعياري المستخدم، وبعد ذلك حساب معامل الارتباط باستخدام العلاقة السابقة نفسها. لكن وجد أنَّ معامل الارتباط المتعدد قابل للحساب من خلال معرفة معاملات الارتباط البسيط أيضاً وهذا ما ستوضحه لنا الفقرة الآتية.

(٣, ٤, ٢) العلاقة بين الارتباط المتعدد والارتباط البسيط

لقد رأينا أنَّ العلاقة التي تُعطي الارتباط المتعدد بين ثلاثة متغيرات X, Y, Z هي العلاقة [3,38]، علماً أنَّ المتغير Z هو المتغير التابع وأما X و Y فهما المتغيران المستقلان، ولكن في الواقع يمكننا الحصول على قيمة معامل الارتباط المتعدد إذا علمنا معاملات الارتباط البسيطة بين كل زوج من المتغيرات X, Y, Z ، فعلى سبيل المثال:

١- إذا كان لدينا ثلاثة متغيرات X_1, X_2, X_3 فعندئذ من أجل أي تبديل $(i_1 i_2 i_3)$ للأعداد 1، 2، 3 تكون العلاقة الآتية مُحَقَّقة:

$$r_{i_1; i_2, i_3} = \sqrt{\frac{r_{i_1, i_2}^2 + r_{i_1, i_3}^2 - 2 r_{i_1, i_2}^2 r_{i_1, i_3}^2 r_{i_2, i_3}^2}{1 - r_{i_2, i_3}^2}} \quad [3,39]$$

وهكذا نلاحظ أنَّ قيمة معامل الارتباط المتعدد أكبر أو تساوي قيمة معاملات الارتباط البسيطة. كما يمكن حساب $r_{i_1; i_2, i_3}$ من خلال إحدى العلاقتين الآتيتين أيضاً:

$$r_{i_1; i_2, i_3} = \sqrt{r_{i_1, i_2}^2 + r_{i_1, i_2; i_3}^2 - (1 - r_{i_1, i_2}^2)} \quad [3,40]$$

أو

$$r_{i_1; i_2, i_3} = \sqrt{1 - (1 - r_{i_1, i_2}^2) \cdot (1 - r_{i_1, i_3; i_2}^2)} \quad [3,41]$$

٢- إذا كان لدينا أربعة متغيرات X_1, X_2, X_3, X_4 فعندئذ من أجل أي تبديل $(i_1 i_2 i_3 i_4)$ للأعداد 1، 2، 3، 4 تكون العلاقة الآتية مُحَقَّقة:

$$r_{i_1; i_2, i_3, i_4} = \sqrt{1 - (1 - r_{i_1, i_2}^2) \cdot (1 - r_{i_1, i_3; i_2}^2) \cdot (1 - r_{i_1, i_4; i_2, i_3}^2)} \quad [3,42]$$

٣- إذا كان لدينا k متغير X_1, X_2, \dots, X_k ، فعندئذ من أجل أي تبديل $(i_1 i_2 i_3 \dots i_k)$ للأعداد 1، 2، 3، ... و k ستكون العلاقة الآتية مُحَقَّقة:

$$r_{i_1; i_2, i_3, \dots, i_k} = \sqrt{1 - (1 - r_{i_1, i_2}^2) \cdot (1 - r_{i_1, i_3; i_2}^2) \cdot \dots \cdot (1 - r_{i_1, i_k; i_2, i_3, \dots, i_{k-1}}^2)} \quad [3,43]$$


(٣, ٤, ٢, ١) مثال

لنأخذ مجموعة البيانات الآتية التي تمثّل تطور الطول Y والوزن Z مع العمر X للأطفال منذ الولادة وحتى الشهر 162 من عمره (هذه البيانات أخذت عن كتاب طب الأطفال - نشر جامعة دمشق 1988-1989)، فكانت النتائج كما في الجدول الآتي:

الجدول (٣، ٢٤)

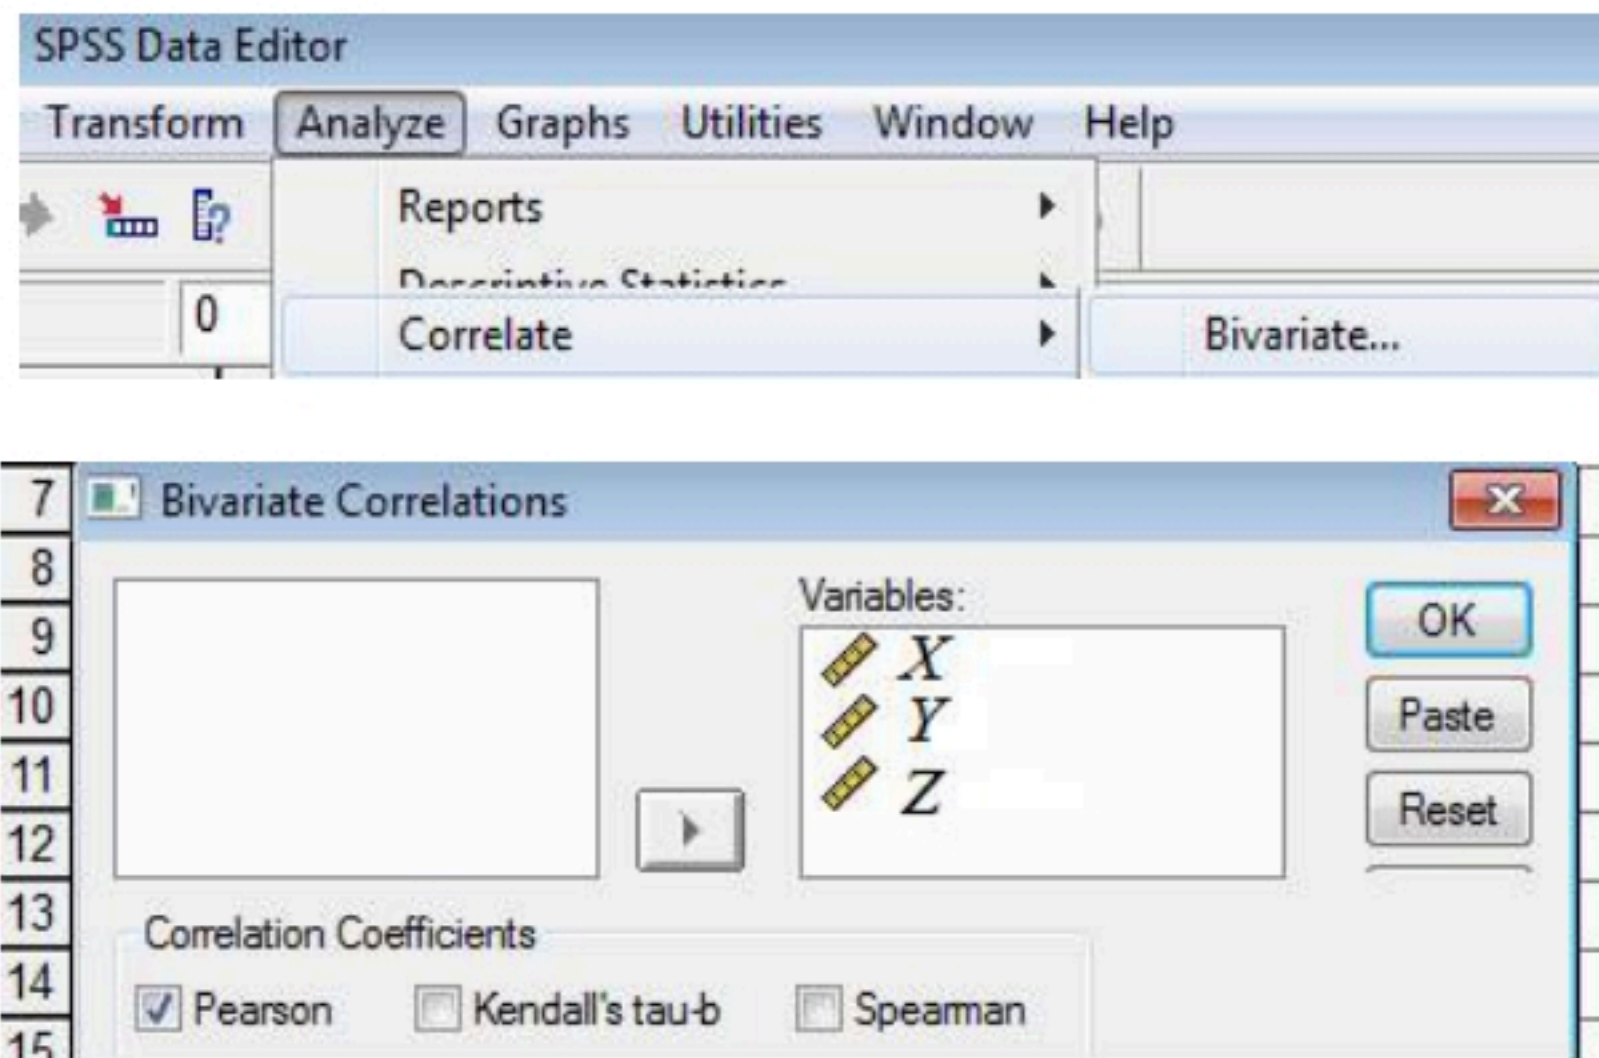
الوزن Z كغ	الطول Y سم	العمر X بالشهر	الوزن Z كغ	الطول Y سم	العمر X بالشهر	الوزن Z كغ	الطول Y سم	العمر X بالشهر
21.80	119.9	84	10.29	78	15	3.36	54.3	0
22.90	122.4	90	11.20	81	18	4.72	55.6	1
23.90	125.0	96	11.80	83.6	21	5.44	58.7	2
25.10	127.5	102	12.40	86.1	24	6.17	61.2	3
26.30	130.0	108	13.20	90.7	30	6.80	63.5	4
27.70	132.6	114	14.50	94.7	36	7.17	65.3	5
29.20	135.1	120	15.40	98.6	42	7.85	67.1	6
30.70	137.7	126	16.10	102.1	48	8.16	68.8	7
32.30	140.2	132	17.10	105.4	54	8.48	70.1	8
33.90	142.7	138	17.80	108.5	60	8.80	71.4	9
35.50	145.0	144	19.00	111.5	66	9.07	72.6	10
37.20	147.3	150	19.90	114.3	72	9.39	73.9	11
38.90	149.6	156	20.80	117.1	78	9.71	74.9	12
40.70	151.9	162						

فلو أخذنا X متغير يرصد الشهر الذي أخذ فيه القياس مع $X = 0$ هي لحظة الولادة، Y متغير يرصد طول الطفل و Z متغير يرصد وزن الطفل، فعندئذ سنحصل على العروض الآتية التي تظهر لنا توزيع النقاط الممثلة لقيم هذه المتغيرات مأخوذة من مثنى مثنى:



وهكذا نلاحظ أنه ثمة علاقة تربط بين كل متغيرين على حدة، وأن هذه العلاقات تتمايز فيما بينها.

الآن لحساب معاملات الارتباط المتعدد (الكلي) لهذه المتغيرات الثلاثة سنقوم أولاً بحساب معاملات الارتباط الخطي البسيط بين هذه المتغيرات، فنجد $r_{XY} = 0.982$ ، $r_{XZ} = 0.994$ و $r_{YZ} = 0.981$. بالطبع كان من الممكن استخدام برنامج SPSS للحصول على قيم الارتباط الخطي البسيط بين المتغيرات من خلال الخطوات الآتية:



فنحصل على التقرير الآتي:

Correlations

		<i>X</i>	<i>Y</i>	<i>Z</i>
<i>X</i>	Pearson Correlation	1	.982**	.994**
	Sig. (2-tailed)		.000	.000
	N	40	40	40
<i>Y</i>	Pearson Correlation	.982**	1	.981**
	Sig. (2-tailed)	.000		.000
	N	40	40	40
<i>Z</i>	Pearson Correlation	.994**	.981**	1
	Sig. (2-tailed)	.000	.000	
	N	40	40	40

ومن ثمَّ سيكون لمعاملات الارتباط المتعدد القيم الآتية:

$$r_{X;Y,Z} = \sqrt{\frac{r_{XY}^2 + r_{XZ}^2 - 2r_{XY}r_{XZ}r_{YZ}}{1 - r_{YZ}^2}} = \sqrt{\frac{0.03724}{0.03764}} = \sqrt{0.989} = 0.995$$

$$r_{Y;X,Z} = \sqrt{\frac{r_{XY}^2 + r_{YZ}^2 - 2r_{XY}r_{XZ}r_{YZ}}{1 - r_{XZ}^2}} = \sqrt{\frac{0.011561}{0.011964}} = \sqrt{0.966} = 0.983$$

$$r_{Z;X,Y} = \sqrt{\frac{r_{XZ}^2 + r_{YZ}^2 - 2r_{XY}r_{XZ}r_{YZ}}{1 - r_{XY}^2}} = \sqrt{\frac{0.035273}{0.035676}} = \sqrt{0.989} = 0.994$$


وبهذا يكون قد تمَّ حساب المعاملات المذكورة آنفاً حيث نلاحظ القوة الكبيرة للارتباط في كل حالة من هذه الحالات الثلاث.

Partial Correlation الجزئي (٣, ٤, ٣)

في كثير من الأحيان قد يرتبط المتغير التابع بالعديد من المتغيرات، ولكن يرغب المرء عادة أن يدرس العلاقة بين المتغير التابع وواحد فقط من هذه المتغيرات المستقلة مع عدم تجاهل المتغيرات الأخرى (وكأنه يبحث في إيجاد معامل الارتباط البسيط بين المتغير التابع ومتغير مستقل واحد قيد الدرس). في مثل هذه الحالة يستخدم المرء معامل الارتباط الجزئي الذي يقيس العلاقة بين المتغير التابع وأحد المتغيرات المستقلة مفترضاً ثبات تأثير بقية المتغيرات المستقلة الأخرى عند مستوى محدد، والفقرة الآتية تشرح لنا هذا المفهوم.

(٣, ٤, ٣, ١) تعريف (الارتباط الجزئي)

لتكن لدينا المتغيرات X_1, X_2, \dots, X_n ، فعندئذ يُعرف **الارتباط الجزئي** على أنه العلاقة المتبادلة الخطية بين متغيرين من هذه المتغيرات لدى ارتباط كل المتغيرات الأخرى بتأثيراتها المتبادلة فيما بينها كما في الشكل التشابكي الآتي (٣, ٣٨).



الشكل (٣, ٣٨)

من أجل توضيح هذا المفهوم سنأخذ الحالة التي يكون اهتمامنا فيها منصّباً على مدى الارتباط الفعلي بين X_2 و X_1 تحت التأثيرات الناتجة عن المتغيرات X_1, X_2, \dots, X_n ، وكذلك سنرمز للارتباط الجزئي بين X_2 و X_1 تحت التأثيرات الناتجة عن المتغيرات X_3, X_4, \dots, X_n بالرمز $X_1, X_2; X_3, X_4, \dots, X_n$ ، وأما قيمة **معامل الارتباط الجزئي** له Partial Correlation Coefficient فسوف نرمز له بـ $r_{1,2;3,4,\dots,n}$ ، علماً أن العدد $n-2$ الذي يمثل عدد المتغيرات X_3, X_4, \dots, X_n يدعى رتبة **الارتباط الجزئي** Order of the Partial Correlation، وأخيراً يُطلق على المتغيرات X_3, X_4, \dots, X_n اسم **المتغيرات المشوشة** Confusing Variables.

في الواقع إن معامل الارتباط الجزئي $r_{1,2;3,4,\dots,n}$ هو مقياس للارتباط بين الانحرافات الآتية (التي سنرمز لها بـ $(X_1 - \bar{X}_1; 3,4,\dots,n)$):

$$(X_1 - \bar{X}_1) - \alpha_{13}(X_3 - \bar{X}_3) - \alpha_{14}(X_4 - \bar{X}_4) - \dots - \alpha_{1n}(X_n - \bar{X}_n)$$

لقيم المتغير X_1 عن دالة انحداره للمتغيرات X_3, X_4, \dots, X_n ، وكذلك مقياس للارتباط بين الانحرافات الآتية (التي سنرمز لها بـ $(X_2 - \bar{X}_2; 3,4,\dots,n)$):

$$(X_2 - \bar{X}_2) - \alpha_{23}(X_3 - \bar{X}_3) - \alpha_{24}(X_4 - \bar{X}_4) - \dots - \alpha_{2n}(X_n - \bar{X}_n)$$

لقيم المتغير X_2 عن دالة انحداره للمتغيرات X_3, X_4, \dots, X_n ، وهكذا فإن معاملات الارتباط الجزئي $r_{1,2;3,4,\dots,n}$ شأنها شأن معامل الارتباط البسيط $r_{1,2}$ ، أي إنه سيكون لدينا:

$$-1 \leq r_{1,2;3,4,\dots,n} \leq +1$$

[3,44]

إن المتغيرات $X_{1;3,4,\dots,n}$ و $X_{2;3,4,\dots,n}$ تُعبّر عن تغيّر X_1 و X_2 بالنسبة إلى المتغيرات المستبعدة X_3 و X_4 و \dots و X_n التي يفهم منها أنه يمكن أخذ X_3 و X_4 و \dots و X_n كثوابت، وأن القيم α_{1i} و α_{2i} من أجل كل $i = 3, 4, \dots, n$ هي التقديرات لمعاملات الارتباط الجزئي.

في الواقع إن معامل الارتباط الجزئي $r_{1,2;3,4,\dots,n}$ يزودنا بالتحليل الإحصائي لسلوك الارتباط من أجل كل مشاهدتين (أو ملحوظتين) من مشاهدات متعددة.

الآن، ومن أجل دراسة معامل الارتباط الجزئي سنميز بين الحالات الآتية:

١- إذا كان تأثير المتغيرات X_3 و X_4 و \dots و X_n على X_1 و X_2 صغيراً لدرجة أن الارتباط الجزئي $X_1, X_2; X_3, X_4, \dots, X_n$ ليس له أهمية مقارنة بالارتباط البسيط بين X_1 و X_2 ، فعندئذ ستكون قيمة $r_{1,2;3,4,\dots,n}$ قريبة جداً من قيمة $r_{1,2}$ ، أي إنه ستكون لدينا:

$$r_{1,2;3,4,\dots,n} \approx r_{1,2}$$

٢- إذا كانت العلاقة الارتباطية بين X_1 وتأثير المتغيرات X_3 و X_4 و \dots و X_n قوية بشكل كبير، وكذلك العلاقة الارتباطية بين X_2 وتأثير المتغيرات X_3 و X_4 و \dots و X_n قوية بشكل كبير أيضاً، فعندئذ ستكون قيمة $r_{1,2;3,4,\dots,n}$ قريبة من الصفر، أي إنه ستكون لدينا:

$$r_{1,2;3,4,\dots,n} \approx 0$$

٣- إن استبعاد تأثير المتغيرات المشوشة يؤثر في العلاقة الارتباطية بين X_1 و X_2 والمعينين بدراستهما، وهذا الاستبعاد سيظهر الارتباط الجزئي $X_1, X_2; X_3, X_4, \dots, X_n$ وكأنه الارتباط البسيط بين X_1 و X_2 ، وهذه الحالة تحدث بشكل خاص عندما يكون لأحد المتغيرات (أو لثلاثة منها أو لخمس منها أو...) من الارتباطات المضاعفة مع المتغيرات المستبعدة له قيمة سالبة.

على كل الأحوال، فإن المدلول العملي لقيمة الارتباط الجزئي $X_1, X_2; X_3, X_4, \dots, X_n$ تعني أن القيمة $r_{1,2;3,4,\dots,n}$ ستكون أكبر من القيمة العملية للارتباط البسيط $r_{1,2}$ ، وأما لحساب قيمة $r_{1,2;3,4,\dots,n}$ فيمكن استخدام العلاقة التراجعية الآتية:

$$r_{1,2;3,4,\dots,n} = \frac{r_{1,2;3,4,\dots,n-1} - r_{1,n;3,4,\dots,n-1} \cdot r_{2,n;3,4,\dots,n-1}}{\sqrt{(1 - r_{1,n;3,4,\dots,n-1}^2) \cdot (1 - r_{2,n;3,4,\dots,n-1}^2)}} \quad [3,45]$$

أو وفقاً للعلاقة التراجعية الآتية أيضاً:

$$r_{1,2;3,4,\dots,n} = \frac{r_{1,2;4,5,\dots,n} - r_{1,3;4,5,\dots,n} \cdot r_{2,3;4,5,\dots,n}}{\sqrt{(1 - r_{1,3;4,5,\dots,n}^2) \cdot (1 - r_{2,3;4,5,\dots,n}^2)}} \quad [3,46]$$

(٢، ٣، ٤، ٣) ملاحظات

١- لاحظ أن العلاقة السابقة [3,45] تصبح غير معرفة عندما يكون لدينا:

$$r_{1,n;3,4,\dots,n-1} = \pm 1 \quad \text{or} \quad r_{2,n;3,4,\dots,n-1} = \pm 1$$

٢- عند استخدام العلاقة السابقة [3,45] يجب على المرء ألا يرفع درجة الارتباط الجزئي كثيراً، بمعنى أنه عليه ألا يستبعد الكثير من المتغيرات المشوشة لأنه يمكن إثبات أن:

$$\mathbf{r}_{1,2;3,4,\dots,n} < \mathbf{r}_{1,2;3,4,\dots,n-1} \quad [3,47]$$

وهكذا فإنه كلما كبرت قيمة k أكثر فأكثر فإن قيمة $\mathbf{r}_{1,2;3,4,\dots,n}$ ستقترب من الصفر أكثر فأكثر، ومن ثم من أجل n كبيرة بقدر كاف سيصبح لدينا:

$$\mathbf{r}_{1,2;3,4,\dots,n} \approx 0$$

وهذا يعني بدوره أنه كلما استبعد المرء متغيرات مشوشة أكثر، فإن ذلك سيؤدي إلى ضعف الحكم على الارتباط (أي إنه ليس لديه الكثير ما يقوله في هذه الصدد). إذ إن ذلك الاستبعاد سيؤدي إلى تصغير حدود ما يعرف باسم فترة الثقة المتعلقة بهذه المسألة، ولذلك لدى الدراسة والبحث في المسائل التطبيقية يجب مراعاة المتغيرات الأساسية جميعاً.

٣- في الحالة الخاصة عندما يكون لدينا $k = 4$ نجد أنه يصبح للعلاقة التراجعية [3-45] العرض الآتي:

$$\mathbf{r}_{1,2;3,4} = \frac{\mathbf{r}_{1,2;3} - \mathbf{r}_{1,4;3} \cdot \mathbf{r}_{2,4;3}}{\sqrt{(1 - \mathbf{r}_{1,4;3}^2) \cdot (1 - \mathbf{r}_{2,4;3}^2)}} \quad [3,48-a]$$

في حين يصبح للعلاقة التراجعية [3-46] العرض الآتي:

$$\mathbf{r}_{1,2;3,4} = \frac{\mathbf{r}_{1,2;4} - \mathbf{r}_{1,3;4} \cdot \mathbf{r}_{2,3;4}}{\sqrt{(1 - \mathbf{r}_{1,3;4}^2) \cdot (1 - \mathbf{r}_{2,3;4}^2)}} \quad [3,48-b]$$

وأما في الحالة الخاصة عندما يكون لدينا $k = 3$ فإننا نجد أن لكل من العلاقتين التراجعتين [3,45] و [3,46] العرض الآتي:

$$\mathbf{r}_{1,2;3} = \frac{\mathbf{r}_{1,2} - \mathbf{r}_{1,3} \cdot \mathbf{r}_{2,3}}{\sqrt{(1 - \mathbf{r}_{1,3}^2) \cdot (1 - \mathbf{r}_{2,3}^2)}} \quad [3,49]$$

وهكذا نلاحظ أن حساب العلاقة [3-48-a] و [3-48-b] سيؤول إلى استخدام العلاقة [3-49]، ومن ثم استخدام معاملات الارتباط البسيط. لذلك عند حساب معاملات الارتباط الجزئي علينا أولاً تعيين جميع معاملات الارتباط البسيط ومن ثم حساب معاملات الارتباط الجزئي $\mathbf{r}_{1,2;3,4,\dots,n}$ ، وهذا بدوره سيتطلب جهداً كبيراً، ولذلك قدّمت طرائق أخرى لحساب معاملات الارتباط الجزئي $\mathbf{r}_{1,2;3,4,\dots,n}$ ، ولكننا لسنا بصدد تقديمها هنا ويمكن لمن يود الاطلاع عليها أن يعود إلى المراجع ذات الصلة بهذا الموضوع والمذكور بعض منها في فهرس المراجع في نهاية هذا الكتاب.

٤- بالعودة إلى الملاحظة السابقة (٣) من هذه الفقرة فإنه يمكن تبين أن:

$$\mathbf{r}_{1,2;3} = \sqrt{\alpha_{1,3} \cdot \alpha_{2,3}}$$

علماً أن $\alpha_{1,3}$ هو معامل الانحدار لـ X_1 بالنسبة إلى X_3 لدى تثبيت X_2 ، وأما $\alpha_{2,3}$ فهو معامل الانحدار لـ X_2 بالنسبة إلى X_3 لدى تثبيت X_1 .

الآن، وبشكل مماثل لما سبق نجد أن:

$$\mathbf{r}_{1,2;3,4} = \sqrt{\alpha_{1,2;3,4} \cdot \alpha_{2,1;3,4}}$$

علماً أنَّ $\alpha_{1,2;3,4}$ هو معامل انحدار المتغير X_1 بالنسبة إلى X_2 لدى تثبيت المتغيرين X_3 و X_4 ، وأما $\alpha_{2,1;3,4}$ فهو معامل انحدار المتغير X_2 بالنسبة إلى X_1 لدى تثبيت المتغيرين X_3 و X_4 .

(٣, ٤, ٣, ٣) مثال

بالعودة إلى المثال (١-٢-٤-٣) حيث لدينا:

$$\mathbf{r}_{1,2} = \mathbf{r}_{XY} = 0.982 \quad \& \quad \mathbf{r}_{1,3} = \mathbf{r}_{XZ} = 0.994 \quad \& \quad \mathbf{r}_{2,3} = \mathbf{r}_{YZ} = 0.981$$

ومن ثمَّ سيكون:

$$\mathbf{r}_{1,2;3} = \frac{\mathbf{r}_{1,2} - \mathbf{r}_{1,3} \cdot \mathbf{r}_{2,3}}{\sqrt{(1 - \mathbf{r}_{1,3}^2) \cdot (1 - \mathbf{r}_{2,3}^2)}} = \frac{0.982 - 0.994 \times 0.981}{\sqrt{(1 - 0.994^2) \cdot (1 - 0.981^2)}} = 0.3245$$

وبالمثل نجد أنَّ:

$$\mathbf{r}_{1,3;2} = \frac{\mathbf{r}_{1,3} - \mathbf{r}_{1,2} \cdot \mathbf{r}_{3,2}}{\sqrt{(1 - \mathbf{r}_{1,2}^2) \cdot (1 - \mathbf{r}_{3,2}^2)}} = \frac{0.994 - 0.982 \times 0.981}{\sqrt{(1 - 0.982^2) \cdot (1 - 0.981^2)}} = 0.8366$$

وأخيراً يكون لدينا:

$$\mathbf{r}_{2,3;1} = \frac{\mathbf{r}_{2,3} - \mathbf{r}_{2,1} \cdot \mathbf{r}_{3,1}}{\sqrt{(1 - \mathbf{r}_{2,1}^2) \cdot (1 - \mathbf{r}_{3,1}^2)}} = \frac{0.981 - 0.982 \times 0.994}{\sqrt{(1 - 0.982^2) \cdot (1 - 0.994^2)}} = 0.2368$$

(٣, ٤, ٤) العلاقة بين الارتباط المتعدد والارتباط الجزئي

يمكن للمرء استنتاج معاملات الارتباط المتعدد لدى معرفة معاملات الارتباط الجزئي، فعلى سبيل المثال إذا كان لدينا $n = 3$ فعندئذ من أجل $j, \ell, k \in \mathbb{N}_3$ مع $j \neq \ell \neq k$ فإنَّ معاملات الارتباط المتعدد بدلالة معاملات الارتباط الجزئي تُعطى بالعلاقة الآتية:

$$1 - \mathbf{r}_{j;\ell,k}^2 = \left(1 - \mathbf{r}_{j,\ell}^2\right) \cdot \left(1 - \mathbf{r}_{j,k;\ell}^2\right) \quad [3,50]$$

وأما إذا كان لدينا $n = 4$ فعندئذ من أجل $j, \ell, k, m \in \mathbb{N}_4$ مع $j \neq \ell \neq k \neq m$ فإنَّ معاملات الارتباط المتعدد بدلالة معاملات الارتباط الجزئي تُعطى باستخدام العلاقة الآتية:

$$1 - \mathbf{r}_{j;\ell,k,m}^2 = \left(1 - \mathbf{r}_{j,\ell}^2\right) \cdot \left(1 - \mathbf{r}_{j,k;\ell}^2\right) \cdot \left(1 - \mathbf{r}_{j,m;\ell,k}^2\right) \quad [3,51]$$

كذلك يمكن حساب معاملات الارتباط الجزئي بدلالة معاملات الارتباط الكلي، فعلى سبيل المثال إذا كان لدينا $n = 3$ فعندئذ من أجل $j, \ell, k \in \mathbb{N}_3$ مع $j \neq \ell \neq k$ فإنَّ معاملات الارتباط الجزئي تُعطى بدلالة معاملات الارتباط المتعدد باستخدام العلاقة الآتية:

$$\mathbf{r}_{j,\ell;k} = 1 - \frac{1 - \mathbf{r}_{j;\ell,k}^2}{1 - \mathbf{r}_{j,\ell}^2} \quad [3,52]$$

وأما إذا كان لدينا $n = 4$ فعندئذ من أجل $j, \ell, k, m \in \mathbb{N}_4$ مع $j \neq \ell \neq k \neq m$ فإنَّ معاملات الارتباط الجزئي تُعطى بدلالة معاملات الارتباط المتعدد باستخدام العلاقة الآتية:

$$\mathbf{r}_{j,\ell;k,m} = \frac{\mathbf{r}_{j,\ell;k} - \mathbf{r}_{j,m;k} \cdot \mathbf{r}_{\ell,m;k}}{\sqrt{(1 - \mathbf{r}_{j,m;k}^2) \cdot (1 - \mathbf{r}_{\ell,m;k}^2)}} \quad [3,53]$$

وهكذا بالنسبة إلى بقية الحالات الممكنة.

(١, ٤, ٤, ٣) مثال

لتكن لدينا البيانات الإحصائية الآتية:

الجدول (٣, ٢٥)

i	1	2	3	4	5	6	7	8
X_3	11	10	9	10	9	10	11	12
X_3	8	7	6	5	6	7	8	9
X_3	9	8	7	6	5	4	3	2

ف نجد أنَّ:

$$\mathbf{r}_{1,2} = 0.843 \quad \& \quad \mathbf{r}_{1,3} = -0.394 \quad \& \quad \mathbf{r}_{2,3} = -0.356$$

ومن ثمَّ تكون قيمة معامل الارتباط الجزئي $\mathbf{r}_{1,2;3}$ تساوي:

$$\mathbf{r}_{1,2;3} = \frac{\mathbf{r}_{1,2} - \mathbf{r}_{1,3} \cdot \mathbf{r}_{2,3}}{\sqrt{(1 - \mathbf{r}_{1,3}^2) \cdot (1 - \mathbf{r}_{2,3}^2)}} = 0.818$$

وأخيراً لنحسب معامل الارتباط المتعدد $\mathbf{r}_{1;2,3}$ بدلالة معاملات الارتباط الجزئية حيث لدينا:

$$1 - \mathbf{r}_{1;2,3}^2 = (1 - \mathbf{r}_{1,2}^2) \cdot (1 - \mathbf{r}_{1,3;2}^2)$$

علماً أنَّ:

$$\mathbf{r}_{1,3;2} = \frac{\mathbf{r}_{1,3} - \mathbf{r}_{1,2} \cdot \mathbf{r}_{2,3}}{\sqrt{(1 - \mathbf{r}_{1,2}^2) \cdot (1 - \mathbf{r}_{2,3}^2)}} = -0.187$$

وبالتعويض ينتج لدينا:

$$1 - \mathbf{r}_{1;2,3}^2 = (1 - 0.843^2) \cdot (1 - (-0.187)^2) = 0.279$$

ومن هذه الأخيرة نستنتج أنَّ $\mathbf{r}_{1;2,3} = 0.721$.

هذا ما تيسر تقديمه من أجل الجزء النظري والتطبيقي لهذا الفصل

تمارين الفصل الثالث

١- لتكن لدينا مجموعة من البيانات الإحصائية التي تمثل قياسات الجهد الكهربائي والتيار (x_i, y_i) في 18 نقطة من دائرة كهربائية:

X	31	30	29	12	11	10	9	7	5
Y	35	34	33	15	16	16	15	14	13
X	30	20	19	18	17	20	19	18	17
Y	24	23	22	21	24	21	24	23	22

والمطلوب ما يلي:

- تمثيل هذه البيانات على لوحة الانتشار.
- احسب قيمة معامل ارتباط بيرسون لهذه المشاهدات.
- تعيين مستقيم انحدار X على Y وكذلك Y على X .
- ارسم مستقيمي الانحدار السابقين على لوحة الانتشار.
- استخدم مستقيم الانحدار المناسب لتقدير القيمة الموافقة لـ $x = 22.45$ وكذلك القيمة الموافقة لـ $y = 19.55$.

٢- لتكن لدينا مجموعة من البيانات الآتية التي تعطينا X مستوى تماسك مادة صناعية مع Y درجات الحرارة لعشر عينات من هذه المادة:

رقم العينة	1	2	3	4	5	6	7	8	9	10
X	جيد	جيد جداً	وسط	جيد	وسط	جيد جداً	جيد	ضعيف	جيد	ضعيف جداً
Y	9	10	6.5	7.5	8.5	9.5	7.5	4	8	1.5

والمطلوب تعيين قيمة معامل الارتباط لهذه البيانات، ومن ثم مناقشة النتيجة.

٣- لتكن لدينا مجموعة من البيانات الآتية التي تعطينا مستوى قدرات عشرة من الطلاب في مقرري الحوسبة X والإحصاء Y :

رقم العنصر	1	2	3	4	5	6	7	8	9	10
X	جيد	جيد جداً	وسط	جيد	وسط	جيد جداً	جيد	ضعيف	جيد	ضعيف جداً
Y	جيد جداً	جيد جداً	وسط	وسط	جيد	جيد	جيد	وسط	جيد	ضعيف

والمطلوب تعيين قيمة معامل الارتباط لهذه البيانات، ومن ثم مناقشة النتيجة.

٤- لتكن لدينا بيانات إحصائية معطاة من خلال الجدول الآتي:

			رتب X					Total
			1	2	3	4	5	
			حدود الفئة	5→10	10→15	15→20	20→25	
رتب Y	1	5→15	15	5	-	1	-	
	2	15→25	20	13	5	2	1	
	3	25→35	30	28	16	10	5	
	4	35→45	15	12	5	-	1	
	5	45→55	6	4	2	-	-	
Total								

والمطلوب تعيين قيمة معامل الارتباط لهذه البيانات، ومن ثم مناقشة النتيجة.

٥- لتكن لدينا مجموعة من البيانات الإحصائية الآتية:

i	1	2	3	4	5	6	7	8	9	10
X	0.2	0.35	1	0.25	1.1	3	2.5	1.75	1.5	0.75
Y	-1.61	-1.05	0.1	-1.5	0.1	1.15	0.95	0.57	0.35	- 0.3

والمطلوب ما يلي:

أ- تمثيل هذه البيانات على لوحة الانتشار.

ب- تعيين خط الانحدار المناسب لهذه البيانات.

ج- تعيين معادلة هذا الخط بعد ردها إلى الشكل الخطي.

٦- لتكن لدينا مجموعة من البيانات الإحصائية الآتية:

i	1	2	3	4	5	6	7	8	9	10
X	2	0.35	1.5	2	2.75	3	2.5	3.5	4.5	0.75
Y	4.5	0.1	2.2	3.75	7.7	9.5	6	12.5	21	0.5

والمطلوب ما يلي:

أ- تمثيل هذه البيانات على لوحة الانتشار.

ب- تعيين خط الانحدار المناسب لهذه البيانات.

ج- تعيين معادلة هذا الخط بعد ردها إلى الشكل الخطي.

٧- لتكن لدينا مجموعة من البيانات الإحصائية الآتية:

i	1	2	3	4	5	6	7	8	9	10
X	1	3	0.5	0.25	1.1	2	2.5	1.75	1.25	2.75
Y	1.2	0.4	2.1	4.1	0.9	0.47	0.45	0.56	0.7	0.38

والمطلوب ما يلي:

أ- تمثيل هذه البيانات على لوحة الانتشار.

ب- تعيين خط الانحدار المناسب لهذه البيانات.

ج- تعيين معادلة هذا الخط بعد ردها إلى الشكل الخطي.

٨- لتكن لدينا مجموعة من البيانات الإحصائية الآتية:

i	1	2	3	4	5	6	7	8	9	10
X	0.2	1.35	1.75	2.25	1.5	3	2.5	0.8	1.5	0.5
Y	1.3	3.75	5.8	10	4.6	20	12.3	2.1	5.1	1.7

والمطلوب ما يلي:

أ- تمثيل هذه البيانات على لوحة الانتشار.

ب- تعيين خط الانحدار المناسب لهذه البيانات، ومن ثم تعيين معادلة هذا الخط بعد ردها إلى الشكل الخطي.

٩- في دراسة لمعرفة مدى تأثير النبضات العابرة المترابكة على خط الجهد المغذي للمنازل 220 فولط (هذه النبضات تنتج من بدء إقلاع الأجهزة الموصولة على هذه الخطوط وقد تبلغ نحو 600 فولت أو أكثر ولكن بتردد عال نسبياً) على نوع من الأجهزة الإلكترونية الدقيقة أخضعت عينة عشوائية مكونة من خمسين جهازاً لهذه الدراسة، وبحيث ربط منها عشرون جهازاً على خط تغذية مستقل عن الخط العام للتغذية من أجل عملية المقارنة، فوجدنا النتائج الآتية:

		الظاهرة الأولى (التعرض للنبضات)		Total
		أجهزة وصلت إلى خط تغذية مستقل (لم تتعرض لنبضات عابرة)	أجهزة وصلت إلى خط التغذية العام (تعرضت لنبضات عابرة)	
الظاهرة الثانية (الإصابة بالتلف)	أصبحت بالتلف	1	4	
	لم تصب بالتلف	19	26	
Total				

والمطلوب تبيان العلاقة ما بين ظاهرة تلف الأجهزة وظاهرة التعرض للنبضات العابرة المحمولة على خط التغذية العام.

١٠- لتكن لدينا البيانات الإحصائية الآتية:

<i>i</i>	1	2	3	4	5	6	7	8
X_1	10	9	8	7	4	5	10	7
X_2	9	8	7	6	5	6	9	8
X_3	8	7	6	5	6	7	8	9

والمطلوب ما يلي:

- أ- حساب قيم معاملات الارتباط المتعدد $r_{1;23}$ و $r_{3;12}$ بدلالة معاملات الارتباط البسيط.
- ب- حساب قيم معاملات الارتباط الجزئية $r_{1,2;3}$ و $r_{1,3;2}$ بدلالة معاملات الارتباط البسيط.


١١- لدى إجراء دراسة على مدى تأثير الجهد الكهربائي ذي التوتر العالي (والمحمّل على خطوط التغذية القريبة من المنازل السكنية) على صحة الأشخاص القاطنين على مسافة عشرة أمتار عن هذه الخطوط وجدت النتائج المدوّنة كما في الجدول الآتي:

		الظاهرة الأولى (التوتر) X				Total
		توتر عال جداً 100 KV	توتر عال 20 KV	توتر متوسط 5000 V	توتر منخفض 220 V	
الظاهرة الثانية Y (الحالة الصحية)	أشخاص لم يعانون من أمراض	5	15	85	100	
	أشخاص بدت عليهم أمراض	50	25	15	5	
Total						


والمطلوب تبيان مدى ارتباط ظاهرة الأمراض التي بدت على الأشخاص مع قيمة التوتر الكهربائي القريب من موقع سكنهم.

١٢- لتكن لدينا مجموعة بيانات إحصائية (x_i, y_i) مع $N_{10} \ni i$ ومقدمة من خلال لوحة الانتشار الآتية، والمطلوب ما يلي:

- أ- حساب قيمة معامل ارتباط بيرسون لهذه المشاهدات.
 ب- تعيين معادلة مستقيم انحدار X على Y ، ومن ثم رسمه على لوحة الانتشار.
 ج- استخدم معادلة مستقيم الانحدار لتقدير القيمة الموافقة لـ $x = 3.5$.



١٣- لتكن لدينا مجموعة بيانات إحصائية (x_i, y_i) مع $N_{10} \ni i$ ومقدمة من خلال لوحة الانتشار الآتية



والمطلوب ما يلي:

- أ- حساب قيمة معامل ارتباط بيرسون لهذه المشاهدات.
 ب- استنتاج معادلة مستقيم انحدار X على Y من الرسم المعطى.
 ج- استخدم معادلة مستقيم الانحدار لتقدير القيمة الموافقة لـ $x = 104$.

الفصل الرابع

الفضاء الاحتمالي، الاحتمالات الشرطية واستقلال الحوادث

PROBABILITY SPACE, CONDITIONAL PROBABILITY & INDEPENDENCE OF EVENTS

(٤, ١) الفضاء الاحتمالي لتجربة عشوائية

Probability Space for a Random Experiment

إن مفهوم الفضاء الاحتمالي لا يُعدّ من المفاهيم الرياضية القديمة إذا ما قورن بمفاهيم رياضية أخرى مثل الفضاء المتجهي وفضاء هيلبرت، حيث تبلور هذا المفهوم بشكل واضح بعد تقديم ما يُعرف باسم **مسلمات كلموغوراف** للفضاء الاحتمالي (عام 1933) التي قُدمت من قبل الرياضي الروسي **كلموغوراف** (1903-1987) Andrey Nikolaevich Kolmogorov حيث أخذ هذا التاريخ كنقطة بداية للنظرية الحديثة للاحتتمالات، وذلك لأنّ هذه المسلمات لم تستوعب قطاع الاحتمالات التقليدية وحسب، وإنّما استطاعت أن تنسجم مع متطلبات العلوم الطبيعية والتقنية لدى دراسة التوزيعات ذات البعد غير المنته أيضاً.

في الحقيقة إنّ أول بحث قُدم في إطار النظرية الحديثة للاحتتمالات يعود إلى الرياضي الروسي **برنشتاين** Sergei Natanovich Bernstein (1880-1968)، وللرياضياتي الفرنسي **بوريل** Félix Édouard Justin Émile Borel (1871-1956)، إلّا أنّ كلموغوراف كان له الأثر الأكبر في تلك الآونة، وذلك بعد أن قام بنشر كتابه المفاهيم الأساس للحساب الاحتمالي عام 1933 الذي تضمّن مسلمات الحساب الاحتمالي، والمسلمات العامة لنظرية الاحتمالات القائمة على نظرية القياس. كما أدخل مفهوم جبر الحوادث لأول مرة من قبل الرياضي والفيلسوف الأوكراني **غليفينكو** Valery Ivanovich Glivenko (1897-1940) وذلك عام 1939.

الآن، ولتوضيح مفهوم الفضاء الاحتمالي لا بدّ لنا أولاً أن نتعرّف على ما تعنيه عبارة علم الاحتمالات، وهذا المصطلح ذو علاقة وطيدة بمفهوم التجربة العشوائية، علماً أنّ الإحصائيين يستخدمون كلمة تجربة لوصف أي عملية تولّد مجموعة من البيانات، ومن أجل الوصول إلى هذا التوضيح سننطلق من الحقيقة الآتية:

إنّ التجارب التي يقوم بها المرء تقسم عادةً إلى صنفين:



الأول: تجارب تكون نتائجها معروفة مسبقاً وقابلة للتخمين بشكل دقيق، ومن الأمثلة على ذلك تجربة تفاعل حمض كلور الماء مع كمية من الألمنيوم النقي، فعندئذ سيتّج لدينا (وبكل تأكيد) كلور الألمنيوم وهيدروجين بالإضافة إلى كمية من الحرارة، وأكثر من ذلك يمكننا حساب الكميات الناتجة بدقة عالية جداً عند معرفة الكميات الداخلة في التفاعل. إنّ هذا الصنف من التجارب التي يمكن الحكم على نتائجها مسبقاً وبدقة تُدعى **تجارب نظامية** Regular Experiments.



الثاني: خاص بالتجارب التي لا يمكن معرفة نتائجها بشكل دقيق مسبقاً، وكل ما يُعرف عنها أنّ النتائج ستنتهي إلى مجموعة ما يمكن تعيينها، ومثال على ذلك تجربة إلقاء حجر زهر النرد Die سداسي الوجوه (يوجد

أنواع عديدة من أحجار النرد، ولكن القياسي منها على شكل مكعب، فعندئذ ستكون النتيجة هي ظهور أحد الأرقام 1 وحتى 6. أي إن النتيجة التي ستظهر للأعلى لا يمكن معرفتها مسبقاً أو الجزم بحدوثها، ولكن ستنتهي للمجموعة $\{1, 2, 3, 4, 5, 6\}$ بكل تأكيد. إن هذا الصنف من التجارب يُدعى **تجارب عشوائية** Random Experiments.

في هذا الموضوع قد يتبادر إلى ذهن القارئ طرح السؤال الآتي:

ما هي العشوائية؟

في الواقع إن الإجابة عن هذا السؤال ترتكز على أساسين:

الأول: رياضياتي بحت، ويهتم بما يعنيه التتالي العشوائي للقيم العددية أو الدوال أو القياسات أو ...

الثاني: تطبيقي صرف، ويهتم بالمسألة التي تُحدد إن كانت الحوادث التي تجري في الواقع خاضعة للمعايير الرياضية الخاصة بالعشوائية أم لا.

هكذا نلاحظ أنه لا يمكننا الجزم بتتابع حوادث تطبيقية المنشأ، أهو تتابع عشوائي أم لا؟ قبل وضع تعريف رياضي دقيق لمعنى العشوائية، وهنا نلاحظ أنه حتى في حال تقديم مثل هذا التعريف، فإن المشكلة تبقى قائمة بخصوص توافق الحوادث التطبيقية مع هذا التعريف. إذ إنه من الممكن أن تتطابق العلاقات الجبرية الممثلة لنتائج التجربة مع القانون المولد للقيم العشوائية التي سيتم اعتمادها في الدراسة، وفي مثل هذه الحالة ستزول ظاهرة العشوائية، وستبدو نتائج الدراسة على أنها قيم نظامية وليست عشوائية.

إذن ما العمل لحل هذه المعضلة؟

في الواقع لم يُقدم حتى اليوم تعريف دقيق شامل لمعنى العشوائية رغم الاستخدام الهائل لهذا المصطلح والعدد الكبير جداً للكتب المؤلفة في هذا الصدد، وربما يكون السبب في ذلك (وهذا رأي شخصي) هو العدد الكبير (لا بل الكبير جداً) من العوامل التي تؤثر في نشوء ظاهرة العشوائية، ومنها على سبيل المثال لا الحصر:

١- الأخطاء الناتجة عن القياس، وذلك لأن أي جهاز قياس (ومهما بلغت دقته) سيكون له ارتياب ولو بقدر ضئيل جداً، وهذا الارتياب قد يمكن تقديره، ولكن لا يمكن الجزم بقيمته.


٢- المؤثرات الخارجية في مادة التجربة التي لا يمكن تفاديها أو السيطرة عليها، وهذه المؤثرات كثيرة جداً قد تصل إلى حد تشكيل طيف من المؤثرات المعلوم بعضها، والمجهول بعضها الآخر (كما هو الحال لدى التنبؤ بهطول الأمطار مثلاً).

٣- مهارة المجرب في تنفيذ التجربة، ويضاف إليها الحالة النفسية للمجرب عند لحظة تنفيذ التجربة (فإن يتلقى نبأ غير سار مثلاً). إذن والحال كذلك كان لا بد من اتفاق على معنى العشوائية. إن هذا الاتفاق ما زال موضع جدل. فمنهم من يعزوها إلى الصدفة البحتة (وهل هناك صدفة بحتة وأخرى غير بحتة، فإن كان هناك مثل هذا التصنيف فإنه من المنطقي أن تنفي إحداها الأخرى)، وهنا يطرح الرأي القائل:

ما هو صدفة بالنسبة لك قد يكون رتيباً بالنسبة لآخر، والأمثلة على ذلك كثيرة جداً، فعلى سبيل المثال: يقوم رجل عدواني الطبع والمزاج بالاعتداء على رجل آخر مجهول بالنسبة له بقصد السلب، فإن ما حصل للرجل المعتدى عليه هو صدفة محضة، في حين أن حدوث الاعتداء كان رتيباً ومخططاً بالنسبة للرجل المعتدي.

في دراستنا هذه سنقبل بأن العشوائية هي مجموعة العوامل والمؤثرات التي تفرض نفسها على التجربة بحيث يصبح معها إمكانية تحديد النتيجة بدقة مطلقة مسبقاً أمر غير ممكن. هذا وقد وردت عبارة العشوائية كترجمة للكلمة اللاتينية Stochastic وتعني يصيب بسهم، وهذه الكلمة استخدمت فيما بعد لتعني **علم العشوائيات** أيضاً الذي هو أحد فروع العلوم الرياضية، ويقصد به عادة **نظرية الاحتمالات** Probability Theory و**الإحصاء الرياضي** Mathematical Statistics (انظر تاريخ الاحتمالات [51]).

الآن، وبما أن المرء يهتم عادة بالنمذجة الرياضية للتجارب، فإنه من الأهمية بمكان معرفة العلم الذي يساعده في عملية النمذجة لهذه التجارب، فعلى سبيل المثال نجد أن النمذجة الرياضية للتجربة النظامية السابقة تقدم من خلال المعادلة الرياضية الآتية:



وهي تندرج في إطار علم الحساب (وهناك بعض التجارب النظامية الأكثر تعقيداً قد تحتاج إلى نماذج رياضية معقدة تتطلب علم التحليل الرياضي والجبر).

أما بخصوص التجارب العشوائية، فإن العلم الذي يهتم بتقديم النماذج الرياضية النظرية لها هو علم الاحتمالات. بمعنى أن علم الاحتمالات هو ذلك الفرع من الرياضيات الذي من ضمن اهتماماته إعداد النماذج الرياضية النظرية للتجارب العشوائية التي تُعرف باسم **الفضاءات الاحتمالية** للتجارب العشوائية أيضاً، وهذا العلم يعد بمثابة حجر الأساس لعلم العشوائيات.

سنقدم فيما يلي عرضاً لكيفية تعيين الفضاء الاحتمالي (النموذج الرياضي النظري) لتجربة عشوائية، ولكن على سبيل التوضيح سنقوم أولاً بتقديم الفضاء الاحتمالي من أجل تجارب عشوائية ذات عدد منته من النتائج، وبعد ذلك نقدم الفضاء الاحتمالي بشكله العام بناءً على مسلمات حيث سيتضح لنا سبب هذا التعميم من خلال مجريات هذا الفصل. لكن نود أن نلفت انتباه القارئ إلى أن الفهم الصحيح والدقيق للاحتتمالات يتطلب معارف من نظرية القياس Measure Theory، ولذلك قمنا بتقديم موجز لأهم المعلومات من نظرية القياس في الملحق (B) قد نحتاجها في هذا الكتاب. لهذا يجب على القارئ الاطلاع على ذلك الملحق إن كان غير ملم بهذه النظرية لأننا سنرد بعض المفاهيم هنا إلى المعلومات المقدمة في ذلك الملحق. أما المفاهيم الرياضية التي سنحتاج إلى بعضها فيفترض أن يكون القارئ ملماً بها، وعلى سبيل التذكير قمنا بتخصيص الملحق (A) لتدوين ما هو ضروري منها.

من أجل تجربة عشوائية مفترضة يرمز لفضائها الاحتمالي بثلاثية $[\Omega, \mathcal{A}, P]$ ، وهكذا نلاحظ أن تعيين الفضاء الاحتمالي لأية تجربة عشوائية يحتاج إلى تعيين ثلاثة عناصر رئيسة على التوالي هي:

Ω وهي مجموعة كل نتائج التجربة العشوائية.

\mathcal{A} وهي أسرة لمجموعات جزئية من Ω تحقق شروطاً محددة (سنأتي على ذكرها لاحقاً)، ويُدعى جبر الحوادث Algebra of Events للتجربة العشوائية.

P وهي دالة حقيقية معرفة على أسرة المجموعات \mathcal{A} ، وتحقق شروطاً محددة (سنأتي على ذكرها لاحقاً)، وتُدعى **قياساً احتمالياً** Probability Measure (أو دالة احتمالية).

الآن لشرح وتوضيح كل عنصر من العناصر الثلاث السابقة، سنفترض أننا أمام تجربة عشوائية مجموعة نتائجها الممكنة Ω (في إطار دراستنا المقبلة سنفترضها غير خالية دائماً).

(١, ١, ٤) تعيين مجموعة نتائج تجربة عشوائية Determination the Set of Outcomes of a Random Experiment

من أجل توضيح كيفية تعيين مجموعة نتائج تجربة عشوائية (أو فضاء الحوادث الابتدائية) سنقدم نوعين من الأمثلة. الأول منها يتعلق بتجارب عشوائية ذات عدد منته من النتائج، وأما الآخر فإنه يتعلق بتجارب عشوائية ذات عدد غير منته من النتائج، ولكن قبل البدء بتقديم هذه الأمثلة نود تقديم الملاحظات الهامة الآتية:

- ١ - عندما نذكر مستقبلاً أنه في تجربة عشوائية ما (مثل: قذف قطع نقود معدنية، أو رمي حجارة نرد، أو سحب كرات من صندوق، أو...) أن الأدوات المستخدمة في توليد النتائج (مثل: قطع النقود المعدنية، أو حجارة النرد، أو الكرات التي في صندوق، أو...) هي أدوات متماثلة إنها نقصد بذلك أنه لا يمكننا التمييز بين هذه الأدوات (انظر الفقرتين ٤ / و ٧ / من المثال الآتي)، وفي حال ذكرنا أن هذه الأدوات متمايزة إنها نقصد بذلك أن النتائج المولدة بتلك الأدوات يمكن تمييز بعضها عن البعض الآخر (انظر الفقرتين ٣ / و ٦ / من المثال الآتي).

٢- عندما نذكر مستقبلاً أن الأدوات المستخدمة في التجربة (مثل: قطع نقود، أو حجارة نرد، أو.....) متوازنة، فإننا نقصد بذلك أن هذه الأدوات مصنعة من مادة متجانسة الكثافة بحيث يصبح لكل نتيجة من نتائج التجربة العشوائية النصيب نفسه في الظهور.

(١, ١, ١, ٤) أمثلة تجارب ذات عدد منته من النتائج

في الأمثلة الآتية لن نهتم بطبيعة النتائج التي سنحصل عليها، وإنما المهم هنا أن يكون عدد هذه النتائج منته

١- لنأخذ تجربة قذف قطعة نقود Coin (وَقصد بذلك قطعة نقود معدنية دوماً) لمرة واحدة فقط، فعندئذ نحصل على إحدى نتيجتين، إما صورة Head ويرمز لها بـ H ، أو شعار Tail ويرمز لها بـ T . إن سبب استخدام Head تعود إلى بعض القطع النقدية المعدنية التي استخدمت في دراسة هذا النوع في التجارب قديماً، حيث كان ينقش على أحد وجهيها صورة رأس أو جذع مع الرأس لشخصية شهيرة في البلد، وأما على الوجه الآخر فإنه ينقش شعار البلد.



بعض النماذج من العملة المعدنية

وهكذا نجد أن مجموعة نتائج هذه التجربة العشوائية هي $\Omega = \{H, T\}$ ، حيث نلاحظ أن عدد النتائج الممكنة لهذه التجربة يساوي 2، وهذا يمثل قدرة مجموعة نتائج التجربة العشوائية Ω ، أي إن $|\Omega| = 2$ ، علماً أن $|\Omega|$ يرمز إلى قدرة (عدد عناصر) المجموعة Ω .

٢- لنأخذ تجربة قذف قطعة نقود واحدة لمرتين متتاليتين، فعندئذ ستكون نتائج التجربة هي عبارة عن ثنائيات مركباتها إما شعاراً أو صورة، ومن ثم فإن مجموعة النتائج لهذه التجربة العشوائية هي:

$$\Omega = \{(H, H), (H, T), (T, H), (T, T)\}$$



حيث نلاحظ أن عدد النتائج الممكنة لهذه التجربة يساوي $|\Omega| = 4 = 2^2$.

٣- لنأخذ تجربة قذف قطعتي نقود متمايزتين لمرة واحدة فقط، فعندئذ ستكون نتائج التجربة هي عبارة عن ثنائيات أيضاً، ومركباتها إما شعار أو صورة، ومن ثم فإن مجموعة النتائج لهذه التجربة العشوائية هي:

$$\Omega = \{(H, H), (H, T), (T, H), (T, T)\}$$



وهنا نلاحظ أن مجموعة النتائج الممكنة لهذه التجربة متطابقة مع مجموعة النتائج الممكنة للتجربة في المثال السابق، والسبب في ذلك يعود لتمايز قطعتي النقود.

ننوه هنا إلى أننا سنكتب (في معظم الحالات - وعلى سبيل التبسيط -) المجموعة السابقة Ω كما يلي:

$$\Omega = \{ HH, HT, TH, TT \}$$

إذا كان ذلك لا يؤدي إلى التباس، وبالمثل بالنسبة إلى المجموعات التي تماثلها.

٤- لنأخذ تجربة قذف قطعتي نقود غير متمايزتين (متماثلتين تماماً) لمرة واحدة فقط، فعندئذ ستكون نتائج التجربة هي:



وكما هو ملاحظ النتائج عبارة عن ثنائيات أيضاً، ولكن مجموعة النتائج الممكنة لهذه التجربة هي:

$$\Omega = \{ (H, H), (H, T), (T, T) \}$$

ومن ثم نلاحظ أن عدد النتائج الممكنة لهذه التجربة تساوي $|\Omega| = 3$ ، وذلك لأنه بسبب عدم التمايز لقطعتي النقود فإنه ينظر إلى النتيجة:



على أنها نتيجة واحدة فقط حيث لا يمكننا معرفة تبعية المركبة الأولى (وبالمثل المركبة الثانية) أي من القطعة الأولى أم الثانية؟


٥- لنأخذ تجربة رمي حجر نرد Die لمرة واحدة فقط، فعندئذ ستكون مجموعة النتائج لهذه التجربة العشوائية هي:

$$\Omega = \{ 1, 2, 3, 4, 5, 6 \}$$

ومن ثم يكون لدينا $|\Omega| = 6$.

٦- لنأخذ تجربة رمي حجري نرد Two Dice متمايزين ولمرة واحدة فقط، فعندئذ ستكون مجموعة النتائج لهذه التجربة العشوائية هي:

$$\Omega = \left\{ \begin{array}{l} (1,1), (1,2), (1,3), (1,4), (1,5), (1,6), \\ (2,1), (2,2), (2,3), (2,4), (2,5), (2,6), \\ (3,1), (3,2), (3,3), (3,4), (3,5), (3,6), \\ (4,1), (4,2), (4,3), (4,4), (4,5), (4,6), \\ (5,1), (5,2), (5,3), (5,4), (5,5), (5,6), \\ (6,1), (6,2), (6,3), (6,4), (6,5), (6,6) \end{array} \right\}$$



ومن ثم يكون لدينا $|\Omega| = 36 = 6^2$.

٧- لنأخذ تجربة رمي حجري نرد غير متمايزين (متماثلين تماماً) ولمرة واحدة فقط، فعندئذ بسبب التماثل بين حجري النرد سوف

ينظر إلى النتيجة (1,2) و (2,1) على أنها تمثل نتيجة واحدة فقط (ولكن بإمكانية الظهور لمرتين) وذلك لأننا لا نستطيع البت في مصدر العدد 2 (وبالمثل بالنسبة إلى مصدر العدد 1) من أي الحجرين قد نتج، وبناء على ذلك تؤخذ إحداها كممثل للنتيجة فقط. بالمثل بالنسبة لبقية المركبات (i,j) و (j,i) مع $i \neq j$ و $i, j \in \mathbb{N}_6$ ، ومنه يكون لمجموعة نتائج هذه التجربة العشوائية العرض الآتي:

$$\Omega = \left\{ \begin{array}{l} (1,1), (1,2), (1,3), (1,4), (1,5), (1,6), \\ (2,2), (2,3), (2,4), (2,5), (2,6), \\ (3,3), (3,4), (3,5), (3,6), \\ (4,4), (4,5), (4,6), \\ (5,5), (5,6), \\ (6,6) \end{array} \right\}$$

ومن ثم يكون لدينا $|\Omega| = 21$.

٨- لنأخذ تجربة قذف قطعة نقود لـ n مرة متتالية، فعندئذ تكون مجموعة النتائج الممكنة لهذه التجربة العشوائية هي متتالية منتهية من رموز الصور H والشعار T متوضعة بترتيب معين، ومن ثم يكون لمجموعة النتائج لهذه التجربة العشوائية العرض الآتي:

$$\Omega = \{ \omega : \omega = (a_1, a_2, \dots, a_n) ; a_i \in \{H, T\} \text{ و } i \in \mathbb{N}_n \}$$

فلاحظ أن $|\Omega| = 2^n$ ، كما يمكننا الحصول على مجموعة النتائج السابقة نفسها أيضاً من خلال رمي n قطعة نقود متبايزة في آن واحد ولمرة واحدة فقط.

٩- لنأخذ تجربة إلقاء حجرين في آن واحد ولـ n مرة متتالية، فعندئذ يكون لمجموعة النتائج الممكنة لهذه التجربة العشوائية العرض الآتي:

$$\Omega = \{ \omega : \omega = (a_1, a_2, \dots, a_n) ; a_i = (b_1, b_2) \text{ و } b_1, b_2 \in \mathbb{N}_6 \text{ و } i \in \mathbb{N}_n \}$$

فلاحظ أن عدد النتائج الممكنة لهذه التجربة يساوي $|\Omega| = 36^n = (6^2)^n$.

١٠- تجربة السحب مع الإعادة Pulling out with Replacement



لنفترض أنه لدينا وعاء يحوي m كرة مرقمة من 1 وحتى m ، وسنفترض أنها تتمايز بعضها عن بعض من خلال الرقم المدون عليها فقط. نخلط هذه الكرات جيداً ومن ثم نُسحب كرة من الوعاء (دون التعمد في سحبها، أي بطريقة عشوائية) ويسجل رقمها، ثم نعيدها إلى الوعاء ثانية. نخلط الكرات من جديد بشكل جيد ومن ثم نُسحب كرة من الوعاء (دون التعمد في سحبها) ويسجل رقمها ثم تعاد إلى الوعاء من جديد، وعلى هذا النحو تُكرر هذه العملية لـ n مرة متتالية (إن هذا النوع من التجارب يعرف باسم تجربة السحب مع الإعادة)، فإذا كنا مهتمين بترتيب نتائج السحب، أي إننا مهتمين بترتيب النتائج كما نحصل عليها وبغض النظر عن حصولنا عليها سابقاً أم لا، فعلى سبيل المثال يُنظر إلى تسلسل النتائج الآتية على أنها نتائج مختلفة بعضها عن البعض الآخر:

$$\underbrace{1, 2, 3, 2, 4, 5, 6, \dots, k}_{\text{نتيجة -1}} \text{ و } \underbrace{1, 2, 2, 3, 4, 5, 6, \dots, k}_{\text{نتيجة -2}} \text{ و } \underbrace{1, 2, 3, 4, 2, 5, 6, \dots, k}_{\text{نتيجة -3}} \text{ و } \dots$$

مع $1 \leq k \leq m$ ، فعندئذ سيكون لمجموعة نتائج هذه التجربة العشوائية العرض الآتي:

$$\Omega = \{ \omega : \omega = (a_1, a_2, \dots, a_n) ; a_i \in \mathbb{N}_m \text{ و } i \in \mathbb{N}_n \} \Rightarrow |\Omega| = m^n$$

وإذا كنا غير مهتمين بترتيب نتائج السحب (بمعنى أننا لا نهتم بترتيب المركبات) ومن ثم لا نهتم في أي سحب سنحصل على رقم معين، وإننا ما يهمنا هو إن كنا سنحصل على هذا الرقم أم لا، فعلى سبيل المثال يُنظر إلى تسلسل النتائج الآتية على أنها تمثل نتيجة واحدة فقط:

$$\underbrace{1, 2, 3, 2, 4, 5, 6, \dots, k}_{\text{نتيجة -1}} \text{ و } \underbrace{1, 2, 2, 3, 4, 5, 6, \dots, k}_{\text{نتيجة -2}} \text{ و } \underbrace{1, 2, 3, 4, 2, 5, 6, \dots, k}_{\text{نتيجة -3}} \text{ و } \dots$$

مع $1 \leq k \leq m$ ، فعندئذ سيكون لمجموعة نتائج هذه التجربة العشوائية العرض الآتي:

$$\Omega = \{ \omega : \omega = [a_1, a_2, \dots, a_n] ; a_i \in \mathbb{N}_m \text{ \& } i \in \mathbb{N}_n \} \Rightarrow |\Omega| = \binom{m+n-1}{n}$$

علماً أنَّ القوس المتوسط المستخدم هنا يعني به أنَّه لا أهمية للترتيب بين المركبات (انظر الجدول (١، ٤)).

١١ - تجربة السحب بدون إعادة Pulling out without Replacement

في كثير من هذه المجالات يتم الاختبار على حساب العنصر الذي خضع للاختبار، وهذا يعني أنَّ الكائن الذي يتم اختياره قد يتم إتلافه نتيجة الاختبار، ومن ثمَّ لا يمكن استبداله بآخر لتنفيذ الاختبار مرةً أخرى، ولذلك فإنَّ التعامل مع السحب دون إعادة (أو دون إحلال) ضروري في مثل هذه الحالات.

لنفترض أنَّ لدينا وعاء يحوي m كرة مرقمة من 1 وحتى m ، ويتميز بعضها عن بعض بالرقم المدون عليها فقط. نخلط هذه الكرات جيداً ومن ثمَّ تُسحب كرة من الوعاء (دون التعمد في سحبها) ويسجل رقمها، ومن ثمَّ توضع جانباً خارج الوعاء، وبعد ذلك نخلط الكرات المتبقية من جديد بشكل جيد ومن ثمَّ تُسحب كرة من الوعاء (دون التعمد في سحبها) ويسجل رقمها وبعد ذلك توضع جانباً خارج الوعاء، وهكذا... تُكرَّر هذه العملية ل n مرةً متتالية مع $m > n$ (هذا النوع من التجارب يُعرف باسم تجربة السحب بدون إعادة)، فإذا كنَّا مهتمين بترتيب نتائج السحب، أي إنه (على سبيل المثال) يُنظر إلى تسلسل النتائج الآتية على أنَّها نتائج مختلف بعضها عن البعض الآخر:

$$\underbrace{1, 2, 3, 4, 5, 6, 7, \dots, k}_{\text{نتيجة } -n_1} \text{ \& } \underbrace{2, 1, 3, 4, 5, 6, 7, \dots, k}_{\text{نتيجة } -n_1} \text{ \& } \underbrace{3, 2, 1, 4, 5, 6, 7, \dots, k}_{\text{نتيجة } -n_1} \text{ \& } \dots$$

مع $2 \leq k \leq m$ ، فعندئذ سيكون لمجموعة نتائج هذه التجربة العشوائية العرض الآتي:

$$\Omega = \{ \omega : \omega = (a_1, a_2, \dots, a_n) ; a_i \in \mathbb{N}_m \text{ \& } i \in \mathbb{N}_n \text{ \& } a_k \neq a_\ell \text{ for } k \neq \ell \}$$

وفي هذه الحالة يكون لدينا:

$$|\Omega| = m(m-1)(m-2) \dots (m-n+1)$$

وأما إذا كان الترتيب لعمليات السحب ليس له أهمية، أي إنه يُنظر إلى تسلسل النتائج الآتية على أنَّها تمثل النتيجة نفسها:

$$\underbrace{1, 2, 3, 4, 5, 6, 7, \dots, k}_{\text{نتيجة } -n_1} \text{ \& } \underbrace{2, 1, 3, 4, 5, 6, 7, \dots, k}_{\text{نتيجة } -n_1} \text{ \& } \underbrace{3, 2, 1, 4, 5, 6, 7, \dots, k}_{\text{نتيجة } -n_1} \text{ \& } \dots$$

مع $2 \leq k \leq m$ ، فعندئذ يكون لمجموعة نتائج هذه التجربة العشوائية العرض الآتي:

$$\Omega = \{ \omega : \omega = [a_1, a_2, \dots, a_n] ; a_i \in \mathbb{N}_m \text{ \& } i \in \mathbb{N}_n \text{ \& } a_k \neq a_\ell \text{ for } k \neq \ell \}$$

ومن ثمَّ يكون عدد النتائج الممكنة لهذه التجربة يساوي:

$$|\Omega| = \binom{m}{n} = \frac{m!}{n!(m-n)!}$$

الجدول الآتي يوضح لنا المثالين الأخيرين من أجل الحالة الخاصة $m = 3$ و $n = 2$.

الجدول (١، ٤)

السحب			
بدون إعادة	مع الإعادة		
(1, 2) (1, 3) (2, 1) (2, 3) (3, 1) (3, 2)	(1, 1) (1, 2) (1, 3) (2, 1) (2, 2) (2, 3) (3, 1) (3, 2) (3, 3)	له أهمية	الترتيب
$m(m-1)\cdots(m-n+1) = 3 \times 2 = 6$	$m^n = 3^2 = 9$	عدد النتائج	
[1, 2] [1, 3] [2, 3]	[1, 1] [2, 2] [3, 3] [1, 2] [1, 3] [2, 3]	ليس له أهمية	
$\binom{m}{n} = \binom{3}{2} = 3$	$\binom{m+n-1}{n} = \binom{4}{2} = 6$	عدد النتائج	

(٢، ١، ٤) ملاحظة

من الأمور المهمة التي يجدر ذكرها في هذا الموضوع هي أن نتائج أمثلة سحب الكرات المُعطاة آنفاً تتوافق مع بعض التوزيعات لجسيمات دقيقة كائنة في حيزٍ محدود، فعلى سبيل المثال نجد في الميكانيك الإحصائي مسألة توزيع n جسيم (هذه الجسيمات قد تكون بروتونات، أو إلكترونات، أو فوتونات أو...) على m حالة (هذه الحالات قد تكون على سبيل المثال مستويات الطاقة). إنَّ هذه الحالات يمكن تمثيلها بصناديق مرقمة بـ 1، 2، ... و m ، فإذا افترضنا أنَّ الجسيمات متمايزة بعضها عن البعض الآخر، ومرقمة بـ 1، 2، ... و n ، فعندئذ يمكن وصف توزيع الـ n جسيم على الـ m حالة بشكل تام من خلال عينة مرتبة (a_1, a_2, \dots, a_n) (لمن يود الاطلاع على هذا النوع من العينات يمكنه الرجوع إلى كتب نظرية المعاينة)، علماً أنَّ a_i هو عدد الحالات التي مرَّ بها الجسيم ذي الرقم i . أما إذا كانت الجسيمات المأخوذة غير متمايزة، فعندئذ يمكن وصف توزيع الـ n جسيم على الـ m حالة بشكل تام من خلال عينة غير مرتبة $[a_1, a_2, \dots, a_n]$ ، علماً أنَّ a_i هو عدد الحالات التي مرَّ بها الجسيم في المرة ذات الرقم i ، وهكذا نلاحظ أنَّ:

العينات المرتبة يقابلها مسألة الجسيمات المتمايزة.

العينات غير المرتبة يقابلها مسألة الجسيمات غير المتمايزة.

وهذا يعني أنَّ حالة العينات المرتبة لدى مسألة اختيار n كرة من صندوق يحوي m كرة هي ذات حالة تقسيم الجسيمات المتمايزة لدى مسألة توزيع n جسيم على m حالة، وبالمثل نجد أنَّ حالة العينات غير المرتبة لدى مسألة اختيار n كرة من صندوق يحوي m كرة هي ذات حالة تقسيم الجسيمات غير المتمايزة لدى مسألة توزيع n جسيم على m حالة. هكذا نصل إلى النتيجة المهمة الآتية (انظر [53]):

إنَّ السحب مع الإعادة يقابلها إمكانية وجود عدد كافي من الجسيمات في حالة واحدة، وأما السحب بدون إعادة فيقابلها عدم إمكانية وجود أكثر من جسيم واحد في الحالة الواحدة.

إنَّ الفيزياء الإحصائية يفيدنا بأنَّ الجسيمات المتمايزة التي لا تخضع لمبدأ باولي Pauli Principle (مبدأ الاستبعاد) ستكون مُحَقَّقة إحصاءة ماكسويل-بولتسمان Maxwell-Boltzmann Statistic، وأما الجسيمات غير المتمايزة التي لا تخضع لمبدأ باولي ستكون مُحَقَّقة إحصاءة بوزي-أينشتاين Bose-Einstein Statistic (ومن أمثال هذه الجسيمات الفوتونات والميزونات ذات النوع π). في حين أنَّه إذا كانت الجسيمات غير متمايزة وتخضع لمبدأ باولي، فإنَّها ستكون مُحَقَّقة إحصاءة فيرمي-ديراك Fermi-Dirac Statistic (ومن أمثال هذه الجسيمات البروتونات والإلكترونات والنيوترونات)، وأخيراً الجسيمات المتمايزة التي تخضع لمبدأ باولي فلا وجود لها في الفيزياء.

الجدول الآتي يوضح لنا أوجه التشابه بين مسألة سحب الكرات وتوزيعات الجسيمات الدقيقة.

الجدول (٢، ٤)

Ω لدى مسألة توزيع n جسيم على m حالة					
		الجسيمات			
		متمايزة	غير متمايزة		
التوزيع	بدون محدودية	m^n إحصاء ماكسويل - بولتزمان	$\binom{m+n-1}{n}$ إحصاء بوزي - أينشتاين	مع الإعادة	السحب
	مع المحدودية	$m(m-1)\cdots(m-n+1)$	$\binom{m}{n}$ إحصاء فيرمي - ديراك	بدون إعادة	
		مرتبة	غير مرتبة		
		لعينة			
		Ω لدى مسألة سحب n كرة من وعاء يحوي m كرة			

(٣، ١، ٤) أمثلة على تجارب ذات عدد غير منته من النتائج:

١- يقذف شخص قطعة نقد، فإذا حصل على صورة ينهي التجربة، وأما إذا حصل على شعار فإنه سيقذف قطعة النقود مرة أخرى، فإن حصل على صورة ينهي التجربة وإلا سيعيد قذف قطعة النقود من جديد. عندئذ ستكون لمجموعة نتائج هذه التجربة العشوائية العرض الآتي:

$$\Omega = \{H, (T, H), (T, T, H), (T, T, T, H), \dots\}$$

ف نجد أن Ω مجموعة غير منتهية ولكنها قابلة للعد.



٢- يقف شخص على حافة بئر دائري الشكل بنصف قطر R ، ويلقي بحصى إلى قاع البئر، فعندئذ نجد أن كل نقطة (x, y) من سطح ماء البئر ستكون نتيجة محتملة للإصابة، ومن ثم ستكون لمجموعة نتائج هذه التجربة العشوائية العرض الآتي:

$$\Omega = \{(x, y) \in \mathbb{R}^2; x^2 + y^2 \leq R^2\}$$

وهنا نلاحظ أن Ω مجموعة غير منتهية، وأكثر من ذلك غير قابلة للعد أيضاً.

والخلاصة:

يتضح لنا مما سبق أنه لا توجد قاعدة محددة لتعيين مجموعة نتائج تجربة عشوائية، وإنما ذلك يتعلّق بطبيعة التجربة والشروط المفروضة عليها. لذلك يجب إمعان النظر في نصوص مسائل الاحتمالات المقدمة لكي نصل إلى نتائج صحيحة، وهذا التحذير واجب في الاحتمالات أكثر منه في بقية الاختصاصات، وذلك لأن الكثير من مسائل الاحتمالات تُقدّم على شكل جمل أو نصوص وليس في شكل علاقات رياضية.

(٢، ١، ٤) جبر الحوادث Algebras of Events

نعلم أن كل تجربة عشوائية تتبعها مجموعة معينة من النتائج الممكنة، وهذه النتائج تُدعى **حوادث ابتدائية** Elementary Events (أو **حوادث ذرية** Atomic Events) ولهذا السبب يُطلق على مجموعة كل نتائج التجربة العشوائية Ω اسم **فضاء الحوادث الابتدائية** Space of Elementary Events أيضاً.

الآن، ومن أجل تجربة عشوائية ما يجب علينا البت في النتيجة المطلوبة إن كانت قد تحققت أم لا، وذلك من أجل مقولة محددة متعلقة بهذه التجربة. هذا يكافئ القول: إنَّ المجرب لا يهتم بأية نتيجة للتجربة سيأخذ، وإنما الذي يهمه هو إن كانت هذه النتيجة ستنتهي إلى مجموعة جزئية أو أكثر من مجموعة كل نتائج التجربة. إنَّ أمثال هذه المجموعات الجزئية تعرف باسم **حوادث** Events، وقد قدم الرياضياتي والعشوائي الروسي **شيريايف** (Albert Nikolaevich Shiryaev (Born 1934) (عالم رياضيات وعشوائيات) مفهوم الحادث على النحو السابق ذكره، وهذا المفهوم مطابق للتعريف الذي قدمه الإحصائي والرياضياتي الفرنسي **لوفي** - Michel Loève (1907-1979) أيضاً (انظر [53] و [39]).

فيما يلي سنقدم بعض المفاهيم المتعلقة بالحوادث المركبة حيث نعلم أنه في علم المنطق يمكننا تشكيل مقولات مركبة بوساطة العمليات المنطقية (و)، (أو) و (كلا) التي يقابلها في نظرية المجموعات **التقاطع** (\cap)، **الاتحاد** (\cup) و **الفرق** (\setminus) على الترتيب، وبما أنَّ الحوادث الناتجة عن التجارب العشوائية تمثل في الرياضيات بمجموعات فإنَّ ذلك يبرر ظهور حوادث مركبة وفقاً للعمليات المنطقية على المجموعات.

(١، ٢، ٣، ٤) تعاريف

- ١- لتكن لدينا تجربة عشوائية مجموع نتائجها Ω ، ولنفترض أنَّ A و B حادثين متعلقين بهذه التجربة (أي إنَّ $A \subseteq \Omega$ و $B \subseteq \Omega$)، فعندئذ:
 - ١- حادث تحقق A أو B (الذي يرمز له بـ $A \cup B$) هو ذلك الحادث الذي يُعبر عن انتهاء نتيجة التجربة ω إلى A أو B أو كليهما.
 - ٢- حادث تحقق A و B معاً (الذي يرمز له بـ $A \cap B$) هو ذلك الحادث الذي يُعبر عن انتهاء نتيجة التجربة ω إلى كلٍّ من A و B في آن واحد.
 - ٣- حادث تحقق A ولكن دون B (والذي يرمز له بـ $A \setminus B$)، هو ذلك الحادث الذي يُعبر عن انتهاء نتيجة التجربة ω إلى الحادث A ولكن دون أن تنتمي إلى الحادث B .

(٢، ١، ٢، ٤) ملاحظات

- ١- في الحالة الخاصة إذا كان حادث $\Omega \supseteq A$ يحوي نتيجة واحدة فقط من نتائج التجربة العشوائية، كأن يكون $A = \{\omega\}$ ، فعندئذ يُقال عن هذا الحادث إنه **حادث بسيط** Simple Event.
- ٢- في الحقيقة يمكننا أن نشق عدداً كبيراً من الحوادث اعتماداً على العمليات الثلاث السابقة، ومن أهمها الحوادث الآتية:
 - أ) **متمم حادث** Complement of an Event: ليكن $\Omega \supseteq A$ حادثاً معطى، فعندئذ **الحادث المتمم** \bar{A} (وسنرمز له بـ \bar{A}) يُعرف على أنه الحادث الذي يتحقق في حال عدم تحقق الحادث A ، وهذا يعني أنه إذا كانت نتيجة التجربة ω لا تنتمي إلى A فإنها ستنتهي إلى متمم A حتماً. أي إنَّ $\bar{A} = \Omega \setminus A$.

ب) **الحادث الأكيد** Certain Event: إنَّ هذا الحادث موافق للحقيقة القائلة: إنه من أجل أي حادث $\Omega \supseteq A$ ستكون أية نتيجة ω من نتائج التجربة منتمة إلى الحادث $A \cup \bar{A}$ بكل تأكيد، ولذلك يدعى أمثال هذا الحادث بـ **الحادث الأكيد**، وبما أنَّ $A \cup \bar{A} = \Omega$ فإنه يرمز للحادث الأكيد بـ Ω أيضاً.

ج) **الحادث المستحيل** Impossible Event: إنَّ هذا الحادث متأت عن حقيقة أنه من أجل أي حادث $\Omega \supseteq A$ ، فإنَّ نتيجة ما ω من نتائج التجربة لا يمكن أن تنتمي إلى الحادث $A \cap \bar{A}$ ولا بأي شكل من الأشكال، أي إنه من المستحيل أن تنتمي ω إلى الحادث $A \cap \bar{A}$ ، ولذلك يدعى أمثال هذا الحادث بـ **الحادث المستحيل**، وبما أنَّ $A \cap \bar{A} = \emptyset$ فإنه يرمز للحادث المستحيل بـ \emptyset أيضاً.


د) الحوادث المتنافية Mutually Exclusive Events: يصادفنا في كثير من الحالات أن انتهاء نتيجة التجربة إلى حادثين $\Omega \supseteq B, A$ بأن واحد أمر غير ممكن (مستحيل)، أي إن $A \cap B = \emptyset$ ، فعندئذ يُقال إن الحادثين A و B متنافيان، أو غير متلائمين، أو بعضه مانع لبعضه الآخر. أما إذا كان لدينا متتالية حوادث $(A_i)_{i \in I}$ من Ω مع I مجموعة قابلة للعد، فعندئذ إذا كان من أجل كل القيم الممكنة ل i و j لدينا $A_i \cap A_j = \emptyset$ $i \neq j$ فعندئذ يُقال عن متتالية الحوادث $(A_i)_{i \in I}$ إنها متنافية مشني Pairwise Mutually Exclusive.

٣- إذا كان لدينا $(A_i)_{i \in I}$ متتالية حوادث متنافية مشني مشني، فإنه يُكتب غالباً (وعلى سبيل التوضيح) $\sum_{i \in I} A_i$ عوضاً عن $\bigcup_{i \in I} A_i$ ، وفي الحالة الخاصة يكتب $A + B$ عوضاً عن $A \cup B$ من أجل A و B حادثين متنافيين.


٤- بناءً على ما سبق نلاحظ أن أي حادث $A = \{\omega_i ; i \in I\}$ من Ω يمكن النظر إليه كحادث مركب من حوادث بسيطة وذلك لأنه يمكننا أن نكتب $A = \sum_{i \in I} \{\omega_i\}$ أيضاً.

(٣، ٢، ١، ٤) أمثلة:


لدينا دائرة كهربائية مكونة من أربع قطع تؤدي النوع نفسه من العمل (دارات مفاتيح)، فإذا رمزنا بـ A_i مع $i \in \mathbb{N}_4$ للحدث الذي يعبر عن عمل القطعة ذات الرقم i ، وبفرض أن الإشارة ستمر من مسار واحد فقط، وأنها أدخلنا إشارة في مدخل الدارة المفترضة، فعندئذ لنعبر عن الحادث الذي يصف عمل هذه الدارة وذلك باستخدام الحوادث A_i .




(أ) الدارة




(ب) الدارة



(ج) الدارة



(د) الدارة



(هـ) الدارة

الحلول: من أجل الدارة:

(أ) نلاحظ أن هذه الدارة تؤدي عملها إذا قامت جميع القطع بأداء عملها، ومن ثم بفرض أن A هو الحادث الذي يعبر عن عمل هذه الدارة فإنه يمكننا كتابة الحادث A باستخدام الحوادث A_i وفقاً للعلاقة الآتية:

$$A = A_1 \cap A_2 \cap A_3 \cap A_4$$

(ب) نلاحظ أن هذه الدارة تؤدي عملها إذا قامت إحدى هذه القطع بأداء عملها، ومن ثم بفرض أن B هو الحادث الذي يعبر عن عمل هذه الدارة فإنه يمكننا كتابة الحادث B باستخدام الحوادث A_i وفقاً للعلاقة الآتية:

$$B = A_1 \cup A_2 \cup A_3 \cup A_4$$

(ج) نلاحظ أن هذه الدارة تؤدي عملها إذا قامت القطع A_1 و A_4 وإحدى القطعتين A_2 أو A_3 بأداء عملها، ومن ثم فإنه بفرض أن C هو الحادث الذي يعبر عن عمل هذه الدارة فإنه يمكننا كتابة الحادث C باستخدام الحوادث A_i وفقاً للعلاقة الآتية:

$$C = A_1 \cap (A_2 \cup A_3) \cap A_4 = (A_1 \cap A_2 \cap A_4) \cup (A_1 \cap A_3 \cap A_4)$$

(د) نلاحظ أن هذه الدارة تؤدي عملها إذا قامت القطعة A_4 وإحدى القطعتين A_1 أو A_2 أو A_3 بأداء عملها، ومن ثم فإنه بفرض أن D هو الحادث الذي يعبر عن عمل هذه الدارة فإنه يمكننا كتابة الحادث D باستخدام الحوادث A_i وفقاً للعلاقة الآتية:

$$D = (A_1 \cup A_2 \cup A_3) \cap A_4 = (A_1 \cap A_4) \cup (A_2 \cap A_4) \cup (A_3 \cap A_4)$$

(هـ) نلاحظ أن هذه الدارة تؤدي عملها إذا قامت إحدى القطعتين A_1 أو A_2 مع إحدى القطعتين A_3 أو A_4 بأداء عملها، ومن ثم فإنه بفرض أن E هو الحادث الذي يعبر عن عمل هذه الدارة فإنه يمكننا كتابة الحادث E باستخدام الحوادث A_i وفقاً للعلاقة الآتية:

$$E = (A_1 \cup A_2) \cap (A_3 \cup A_4) = (A_1 \cap A_3) \cup (A_1 \cap A_4) \cup (A_2 \cap A_3) \cup (A_2 \cap A_4)$$

لقد لاحظنا سابقاً أن كل مقولة متعلقة بتجربة عشوائية هناك حادث يمثلها، والعكس صحيح أيضاً، فمن أجل أي حادث يمكن صياغة مقولة تعبر عنه، فعلى سبيل المثال لو أخذنا تجربة قذف قطعة نقود معدنية لمرتين متتاليتين، وكنا مهتمين بحادث الحصول على صورة واحدة فقط، فعندئذ يعبر عن ذلك رياضياً بالمجموعة $A = \{HT, TH\}$. الآن، وبشكل معكوس لو أعطينا المجموعة $B = \{HH\}$ ، فعندئذ نعبر عن ذلك بالقول: إنه قد تحقق لدينا حادث الحصول على صورتين تماماً في هذه التجربة العشوائية. لكن نعلم أن المقولات تخضع **لجبر المنطق** (جبر بول **Pool algebra**) ولذلك فإن الحوادث المقابلة لهذه المقولات يجب أن تكون منسجمة مع العلاقات المنطقية أيضاً، ومن ثم مع شروط جبر المنطق. أي يجب أن تكون خصائص صف الحوادث لتجربة عشوائية ما مكافئة لخصائص جبر المنطق، ومن ثم العلاقات بين الحوادث سوف تصاغ وتقبل على شكل مسلمات موافقة لجبر المنطق أيضاً. إن هذا الحوار المنطقي دفع الرياضي **غليفيكو** إلى تقديم ما يعرف باسم **جبر الحوادث** الذي عدّه ركيزة أساس في الحساب الاحتمالي عندما قدم مقالته الموسومة بـ مدخل إلى الحساب الاحتمالي عام 1939.

(٤, ٢, ١, ٤) ملاحظة

من أجل Ω مجموعة نتائج تجربة عشوائية ما سنرمز بـ 2^Ω لأسرة كل المجموعات الجزئية من Ω .

والآن سنقدم تعريف ما يُسمى بـ **الجبر** والـ **σ -جبر** فوق Ω .

(٥, ٢, ١, ٤) تعريف (الجبر فوق Ω Algebra on Ω)

لتكن Ω مجموعة نتائج تجربة عشوائية، ولنأخذ \mathcal{A} صف مجموعات جزئي من أسرة كل المجموعات الجزئية لـ Ω (أي إن $2^\Omega \supseteq \mathcal{A}$)، ولنفترض البنود الآتية:

- \mathbf{a}_1 - المجموعة Ω عنصر من \mathcal{A} (أي إن $\Omega \in \mathcal{A}$).
- \mathbf{a}_2 - من أجل أي A و B من \mathcal{A} فإن $A \cup B$ هو عنصر من \mathcal{A} أيضاً (أي إن الصف \mathcal{A} مغلق بالنسبة إلى عملية الاتحاد المنتهي).
- \mathbf{a}_3 - من أجل أي A من \mathcal{A} فإن \bar{A} هو عنصر من \mathcal{A} أيضاً (أي إن الصف \mathcal{A} مغلق بالنسبة إلى عملية التكميم).
- \mathbf{a}_∞ - من أجل أية متتالية $(A_n)_{n \in \mathbb{N}}$ عناصرها من \mathcal{A} فإن $\bigcup_{n=1}^{\infty} A_n$ هو عنصر من \mathcal{A} أيضاً (أي إن الصف \mathcal{A} مغلق بالنسبة إلى عملية الاتحاد غير المنتهي العدود).

عندئذ يُقال إن:

- أ) الصف \mathcal{A} هو جبر Algebra فوق Ω إذا حقق هذا الصف البنود (\mathbf{a}_1) و (\mathbf{a}_2) و (\mathbf{a}_3) .
- ب) الصف \mathcal{A} هو σ -جبر σ -Algebra فوق Ω إذا حقق هذا الصف البنود (\mathbf{a}_1) و (\mathbf{a}_∞) و (\mathbf{a}_3) .

(٦, ٢, ١, ٤) ملاحظة

إذا ذكر أن الصف \mathcal{A} غير خال فإن ذلك يعني أنه يوجد على الأقل عنصر $A \in \mathcal{A}$ ، ولذلك فإذا كان \mathcal{A} جبراً (أو σ -جبر) فإنه بسبب تحقق البند (\mathbf{a}_3) سيكون لدينا $\bar{A} \in \mathcal{A}$ ، وكذلك بحسب البند (\mathbf{a}_2) (أو (\mathbf{a}_∞)) سيستج لدينا أن $A \cup \bar{A} = \Omega$ هو عنصر من \mathcal{A} أيضاً، ولذلك يمكن حذف البند الأول (\mathbf{a}_1) في هذه الحالة (أي إذا أخذ الجبر \mathcal{A} كصف غير خال).

(٧, ٢, ١, ٤) مثال

لنأخذ تجربة قذف قطعة نقود معدنية لمرة واحدة، فعندئذ نعلم أن مجموعة نتائج هذه التجربة العشوائية هي $\Omega = \{H, T\}$ ، ومن ثم سيكون لأسرة كل المجموعات الجزئية من Ω العرض الآتي:

$$2^\Omega = \{\emptyset, \{H\}, \{T\}, \{H, T\} = \Omega\}$$

فلو أخذنا:

$$\begin{aligned} \mathcal{A}_1 &= \{\emptyset, \{H\}, \{T\}, \Omega\} = 2^\Omega & \& \quad \mathcal{A}_2 = \{\emptyset, \{T\}, \Omega\} \\ \mathcal{A}_3 &= \{\emptyset, \{H\}, \Omega\} & \& \quad \mathcal{A}_4 = \{\emptyset, \Omega\} \end{aligned}$$

ف نجد وبكل وضوح أن كلا من \mathcal{A}_1 و \mathcal{A}_4 هو جبر فوق Ω ، وأما \mathcal{A}_2 و \mathcal{A}_3 فإنهما لا يحققان شروط الجبر فوق Ω (شرط الإغلاق بالنسبة إلى عملية التكميم غير محقق). كذلك نجد أن الصف \mathcal{A}_1 هو σ -جبر على Ω ، وذلك لأنه مغلق بالنسبة إلى عملية التكميم وضوحاً، وكذلك مغلق بالنسبة إلى عملية الاتحاد غير المنتهي العدود لأنه:

- لو أخذنا $A_n = \emptyset$ من أجل كل $n \in \mathbb{N}$ ، فعندئذ سيكون لدينا $\bigcup_{n=1}^{\infty} A_n = \emptyset$.
- لو أخذنا $A_n = \Omega$ من أجل كل $n \in \mathbb{N}$ ، فعندئذ سيكون لدينا $\bigcup_{n=1}^{\infty} A_n = \Omega$.
- لو أخذنا $A_n = \emptyset$ من أجل بعض القيم لـ $n \in \mathbb{N}$ سواء كان عددها منتهياً أم غير منته، وباقي عناصر المتتالية $(A_n)_{n \in \mathbb{N}}$ هي $\{H\}$ ، فعندئذ سيكون لدينا $\bigcup_{n=1}^{\infty} A_n = \{H\}$.
- لو أخذنا $A_n = \emptyset$ من أجل بعض القيم لـ $n \in \mathbb{N}$ سواء كان عددها منتهياً أم غير منته، وباقي عناصر المتتالية $(A_n)_{n \in \mathbb{N}}$ هي $\{T\}$ ، فعندئذ سيكون لدينا $\bigcup_{n=1}^{\infty} A_n = \{T\}$.

- لو أخذنا $A_n = \emptyset$ من أجل بعض القيم لـ $\mathbb{N} \ni n$ سواء كان عددها منتهياً أم غير منته، وباقي عناصر المتتالية $(A_n)_{n \in \mathbb{N}}$ مكونة من $\{H\}$ و $\{T\}$ ، فعندئذ سيكون لدينا $\bigcup_{n=1}^{\infty} A_n = \Omega$.
 - لو أخذنا $A_n = \Omega$ من أجل بعض القيم لـ $\mathbb{N} \ni n$ سواء كان عددها منتهياً أم غير منته، وباقي عناصر المتتالية $(A_n)_{n \in \mathbb{N}}$ هي $\{H\}$ ، فعندئذ سيكون لدينا $\bigcup_{n=1}^{\infty} A_n = \Omega$.
 - لو أخذنا $A_n = \Omega$ من أجل بعض القيم لـ $\mathbb{N} \ni n$ سواء كان عددها منتهياً أم غير منته، وباقي عناصر المتتالية $(A_n)_{n \in \mathbb{N}}$ هي $\{H\}$ ، فعندئذ سيكون لدينا $\bigcup_{n=1}^{\infty} A_n = \Omega$.
 - لو أخذنا $A_n = \Omega$ من أجل بعض القيم لـ $\mathbb{N} \ni n$ سواء كان عددها منتهياً أم غير منته، وباقي عناصر المتتالية $(A_n)_{n \in \mathbb{N}}$ مكونة من $\{T\}$ و $\{H\}$ ، فعندئذ سيكون لدينا $\bigcup_{n=1}^{\infty} A_n = \Omega$.
 - لو أخذنا $A_n = \{H\}$ من أجل كل $\mathbb{N} \ni n$ ، فعندئذ سيكون لدينا $\bigcup_{n=1}^{\infty} A_n = \{H\}$.
 - لو أخذنا $A_n = \{T\}$ من أجل كل $\mathbb{N} \ni n$ ، فعندئذ سيكون لدينا $\bigcup_{n=1}^{\infty} A_n = \{T\}$.
 - لو أخذنا $A_n = \{H\}$ من أجل بعض القيم لـ $\mathbb{N} \ni n$ سواء كان عددها منتهياً أم غير منته، وباقي عناصر المتتالية $(A_n)_{n \in \mathbb{N}}$ هي $\{T\}$ ، فعندئذ سيكون لدينا $\bigcup_{n=1}^{\infty} A_n = \Omega$.
 - لو أخذنا $A_n = \{T\}$ من أجل بعض القيم لـ $\mathbb{N} \ni n$ سواء كان عددها منتهياً أم غير منته، وباقي عناصر المتتالية $(A_n)_{n \in \mathbb{N}}$ هي $\{H\}$ ، فعندئذ سيكون لدينا $\bigcup_{n=1}^{\infty} A_n = \Omega$.
- حيث نعلم أن $\emptyset, \Omega, \{H\}, \{T\}$ جميعها عناصر من \mathcal{A} .

أما من أجل \mathcal{A}_4 فإننا نجد بمناقشة مماثلة (وأكثر بساطة) أنه σ -جبر على Ω أيضاً، وأخيراً نلاحظ أن \mathcal{A}_2 و \mathcal{A}_3 لا يحققان شروط الـ σ -جبر على Ω للسبب الذي ذكرناه سابقاً (بخصوص الإغلاق بالنسبة إلى عملية التميم).

(٨، ١، ٤) ملاحظة

من أجل Ω مجموعة نتائج تجربة عشوائية، فإن عناصر الصف \mathcal{A} (جبراً كان أم σ -جبر على Ω) هي حوادث متعلقة بالتجربة العشوائية التي قيد الدرس.

(٩، ١، ٤) نتائج

١- إن كل جبر فوق Ω يكون مغلقاً بالنسبة إلى عملية التقاطع المنتهي، أي إنه من أجل كل A_1, A_2, \dots و A_n من \mathcal{A} فإن $\bigcap_{i=1}^n A_i$ هو حادث من \mathcal{A} أيضاً.

الإثبات: لإثبات ذلك يكفي أن نبين أنه من أجل أي حادثين $A, B \in \mathcal{A}$ يكون $A \cap B \in \mathcal{A}$ أيضاً، وذلك لأنه إذا أخذنا $A_1 = A$ و $A_2 = B$ وأثبتنا أن $A \cap B \in \mathcal{A}$ فإننا نضع من جديد $A := A_1 \cap A_2$ ونأخذ $A_3 := B$ فيكون لدينا من جديد $A \cap B \in \mathcal{A}$ أيضاً، وهكذا دواليك.

الآن لإثبات أن $A \cap B \in \mathcal{A}$ سنطلق من أن $A, B \in \mathcal{A}$ حادثين كفيين، فيكون بحسب الشرط a_3 لدينا \bar{A} و \bar{B} من \mathcal{A} ، وبحسب الشرط a_2 ينتج أن $\bar{A} \cup \bar{B}$ من \mathcal{A} ، ومرة أخرى بحسب الشرط a_3 سيكون $\overline{\bar{A} \cup \bar{B}}$ من \mathcal{A} أيضاً، ومن ثم نحصل على المطلوب بتطبيق قانون ديمورغان (انظر الملحق A) حيث لدينا $A \cap B = \overline{\bar{A} \cup \bar{B}}$.

٢- إن كل σ -جبر على Ω يكون مغلقاً بالنسبة إلى عملية التقاطع غير المنتهي العدود، أي إنه بفرض أن \mathcal{A} هو σ -جبر على Ω ، فعندئذ من أي متتالية حوادث $(A_n)_{n \in \mathbb{N}}$ عناصرها من \mathcal{A} فإن $\bigcap_{n=1}^{\infty} A_n$ هو عنصر من \mathcal{A} أيضاً.

الإثبات: لتكن $(A_n)_{n \in \mathbb{N}}$ متتالية حوادث من \mathcal{A} ، فعندئذ باستخدام قانون دي مورغان وبحسب تعريف الـ σ -جبر يكون لدينا $\bigcup_{i=1}^{\infty} \bar{A}_i = \overline{\bigcap_{i=1}^{\infty} A_i}$ وهو عنصر من \mathcal{A} .

٣- إذا كان \mathcal{A} جبراً على Ω ، فإن كلا الحادتين المستحيل \emptyset والأكيد Ω ينتميان إلى \mathcal{A} أيضاً.

الإثبات: بما أن \mathcal{A} صف غير خال فإنه يوجد على الأقل حادث $A \in \mathcal{A}$ ، ومنه يكون لدينا $A \in \mathcal{A}$ أيضاً، ومن ثم ينتج لدينا بحسب البند الأول من تعريف الجبر أن $A \cup \bar{A} = \Omega$ هو عنصر من \mathcal{A} ، وكذلك بحسب الفقرة السابقة /١/ يكون لدينا $A \cap \bar{A} = \emptyset$ من \mathcal{A} أيضاً. لاحظ هنا أنه من الممكن أن يكون $A = \Omega$ ، ومن ثم ينتج مباشرة أن \emptyset و Ω هي عناصر من \mathcal{A} أيضاً.

٤- بشكل مماثل لما سبق يمكننا إثبات أنه إذا كان \mathcal{A} يشكل σ -جبر فوق Ω فإن الحادتين \emptyset و Ω ينتميان إلى \mathcal{A} أيضاً.

٥- إن كلا من الجبر والـ σ -جبر فوق Ω يكون مغلقاً بالنسبة إلى عملية الفرق بين الحوادث.

الإثبات: ليكن A و B حادثين من \mathcal{A} ، فعندئذ بحسب تعريف الجبر (أو الـ σ -جبر) والفقرات السابقة سيكون لدينا $A \cap \bar{B} = A \setminus B$ وهو عنصر من \mathcal{A} .

٦- لتكن Ω مجموعة نتائج تجربة عشوائية، فعندئذ كل σ -جبر فوق Ω هو جبر فوق Ω أيضاً.

الإثبات: يكفي من أجل ذلك التحقق من البند الأول في تعريف الجبر لأن البند الثاني مشترك بينهما، فلو افترضنا أن \mathcal{A} هو σ -جبر فوق Ω ، ولتكن $(A_n)_{n \in \mathbb{N}}$ متتالية ما من الحوادث في \mathcal{A} وبحيث يكون فيها حادثان $A_i \neq \emptyset$ و $A_j \neq \emptyset$ مع $i \neq j$ قيمتين صحيحتين مثبتتين، وأما باقي الحوادث فهي \emptyset ، فعندئذ سيكون $\bigcup_{n=1}^{\infty} A_n = A_i \cup A_j$ من \mathcal{A} ، وهذا يعني أن \mathcal{A} هو جبر فوق Ω .

٧- لقد لاحظنا في مثال سابق أن بعض الجبر قد تكون σ -جبر أيضاً (انظر المثال (٤, ١, ٢, ٧))، ولكن ليس كل جبر \mathcal{A} فوق Ω هو σ -جبر فوق Ω .

الإثبات: من أجل ذلك لنأخذ مجموعة نتائج التجربة العشوائية Ω غير منتهية ولكن قابلة للعد على، وليكن $\mathcal{A} \supseteq 2^{\Omega}$ معطى كما يلي:

$$\mathcal{A} := \{ A \in 2^{\Omega} ; A \text{ finite or } \bar{A} \text{ finite} \} \quad [4,1]$$

فعندئذ نجد أن هذا الصف \mathcal{A} هو جبر فوق Ω ، ويسمى **جبر المتممات المنتهية** Algebra of Finite Complements، حيث لدينا:

١- إذا كان $A \in \mathcal{A}$ فإن $\bar{A} \in \mathcal{A}$ أيضاً، وذلك للأسباب الآتية:

أ- إذا كان الحادث A منتهياً فإن الحادث \bar{A} يملك متمماً منتهياً لأن $\bar{\bar{A}} = A$.

ب- إذا كان الحادث A يملك متمماً منتهياً فإن \bar{A} يكون منتهياً.

٢- ليكن A و B حادثين من \mathcal{A} فعندئذ سيكون $A \cup B \in \mathcal{A}$ أيضاً، وذلك للأسباب الآتية:

أ) إذا كان الحادثان A و B منتهيين فإن الحادث $A \cup B$ سيكون منتهياً.

ب- إذا كان أحد الحادثين A أو B منتهياً والآخر يملك متمماً منتهياً، ولنفترض على سبيل المثال أن الحادث A منتهياً و B يملك متمماً منتهياً، فإن الحادث $\overline{A \cup B} = \bar{A} \cap \bar{B} \subseteq \bar{B}$ سيكون منتهياً أيضاً، ومن ثم فإن $A \cup B$ يملك متمماً منتهياً.

ج- إذا كان كل من الحادتين A أو B يملك متمماً منتهياً، فعندئذ سيكون الحادث $\overline{A \cup B} = \overline{A} \cap \overline{B} \subseteq \overline{A}$ منتهياً أيضاً، ومن ثم الحادث $A \cup B$ يملك متمماً منتهياً.

لكن هذا الجبر \mathcal{A} ليس σ -جبر فوق Ω وذلك لأنه لو أخذنا (على سبيل المثال) $\Omega = \mathbb{Z}$ ، وأخذنا متتالية الحوادث $(\{n\})_{n \in \mathbb{N}}$ التي عناصرها من \mathcal{A} ، فإننا نجد الآتي:

$$\bigcup_{n=1}^{\infty} \{n\} = \mathbb{N} \notin \mathcal{A} \quad \& \quad \overline{\bigcup_{n=1}^{\infty} \{n\}} = \mathbb{Z} \setminus \mathbb{N} \notin \mathcal{A}$$

وبهذا يتم الإثبات.

٨- في الحالة الخاصة عندما يكون فضاء الحوادث الابتدائية Ω منتهياً، فإن كل جبر فوق Ω هو σ -جبر فوق Ω أيضاً. **الإثبات:** لنفترض أن فضاء الحوادث الابتدائية Ω منتهياً، وليكن $2^{\Omega} \supseteq \mathcal{A}$ جبراً فوق Ω ، فعندئذ لإثبات أن \mathcal{A} هو σ -جبر فوق Ω يكفي إثبات الإغلاق بالنسبة إلى عملية الاتحاد غير المنتهي العدود. بما أن فضاء الحوادث الابتدائية Ω منتهياً فإن عدد الحوادث في \mathcal{A} سيكون منتهياً حتماً، ومنه بأخذ الحوادث A_1, A_2, \dots و A_n من \mathcal{A} مع n عدد طبيعي محدود بحيث يكون $|\mathcal{A}| \leq n$ ، فإنه يمكننا أن نشكل متتالية غير منتهية $(B_i)_{i \in \mathbb{N}}$ عناصرها من \mathcal{A} على النحو الآتي:

$$B_i = \begin{cases} A_i & \text{for } i \leq n \\ \emptyset & \text{for } i > n \end{cases}$$

عندئذ يكون لدينا ما يلي:

$$\bigcup_{i=1}^{\infty} B_i = A_1 \cup A_2 \cup \dots \cup A_n \cup \emptyset \cup \dots \cup \emptyset \cup \dots = \bigcup_{i=1}^n A_i \in \mathcal{A}$$

وهذا يعني أن \mathcal{A} مغلق بالنسبة إلى عملية الاتحاد غير المنتهي العدود أيضاً، وبهذا يتم الإثبات.

(١٠، ٢، ١، ٤) أمثلة

لتكن Ω فضاء الحوادث الابتدائية لتجربة عشوائية ما، فعندئذ:

١- لنأخذ صف الحوادث $\mathcal{A} = \{\emptyset, \Omega\}$ ، فنجد أن \mathcal{A} هو جبر فوق Ω . إن هذا الجبر يُعرف باسم **الجبر المبذل** Trivial Algebra فوق Ω ، وهو أضعف جبر فوق Ω ، بمعنى أنه إذا وجد جبر آخر \mathcal{G} فوق Ω فإنه سيكون لدينا $\mathcal{A} \subseteq \mathcal{G}$. كذلك نجد أن صف الحوادث \mathcal{A} هو σ -جبر فوق Ω أيضاً، ويحمل الاسم السابق نفسه، وهو أضعف σ -جبر فوق Ω أيضاً.

٢- من أجل حادث $A \subset \Omega$ لنأخذ صف الحوادث $\mathcal{A} = \{\emptyset, A, \overline{A}, \Omega\}$ ، فنجد أن هذا الصف يُشكل جبراً فوق Ω (وكذلك يُشكل σ -جبر فوق Ω أيضاً). إن هذا النوع من الجبر يُدعى **الجبر المولد بالحادث** A .

٣- إذا كان Ω منتهياً أو غير منته ولكن قابل للعد على الأكثر، وأخذنا $\mathcal{A} = 2^{\Omega}$ ، فعندئذ سيكون هذا الصف σ -جبر فوق Ω ، وهو أكبر σ -جبر فوق Ω أيضاً، بمعنى أنه إذا كان \mathcal{G} هو σ -جبر فوق Ω ، فإنه سيكون $\mathcal{A} \supseteq \mathcal{G}$ ، ولذلك يُقال عن \mathcal{A} إنه **أقوى جبر** Strongest Algebra أو **أغنى جبر** Richest Algebra فوق Ω (علماً أن هذه التسمية الأخيرة هي اجتهاد وليست من التسميات المتعارف عليها كما للجبر المبذل).

٤- إذا كانت Ω مجموعة نتائج تجربة إلقاء حجر نرد لمرة واحدة، فعندئذ سيكون لدينا $\Omega = \{1, 2, 3, 4, 5, 6\}$ ، ولنأخذ صفوف المجموعات الآتية:

$$\mathcal{A}_1 = \{\emptyset, \Omega, \{1, 3, 5\}, \{2, 6\}, \{2, 5\}, \{1, 3, 4, 6\}, \{1, 2, 3, 5, 6\}\}$$

$$\mathcal{A}_2 = \left\{ \emptyset, \Omega, \{1,3,5\}, \{2,4,6\}, \{2,5\}, \{1,3,4,6\}, \{1,2,3,5\}, \right. \\ \left. \{1,3,4,5,6\}, \{2,4,5,6\}, \{1,2,4,5,6\}, \{3\}, \{1,3\}, \{2\} \right\}$$

$$\mathcal{A}_3 = \left\{ \emptyset, \Omega, \{1,5\}, \{2,3,4,6\}, \{2,5\}, \{1,3,4,6\} \right\}$$

$$\mathcal{A}_4 = \left\{ \emptyset, \Omega, \{1\}, \{2,3,4,5,6\} \right\}$$

فلاحظ أنَّ الصف \mathcal{A}_4 هو الصف الوحيد الذي يحقق شروط الجبر فوق Ω ، ويمثل الجبر المولّد بالحدث $A = \{1\}$. سنعرض فيما يلي إحدى الطرائق المستخدمة في توليد الجبر فوق Ω وذلك بشكل مبسّط، ومن أجل ذلك لنعرّف أولاً التجزئة لمجموعة ما E غير خالية.

(١١، ٢، ١، ٤) تعريف (التجزئة لمجموعة Partition of a Set)

لتكن E مجموعة ما غير خالية و $\mathbb{N} \supseteq I$ (لاحظ أنَّ I مجموعة قابلة للعدّ على الأكثر)، ولنأخذ أسرة المجموعات:

$$\mathbb{Z} = \left\{ Z_i \subseteq E ; i \in I \right\}$$

فعندئذ يُقال عن \mathbb{Z} إنها تجزئة لـ E إذا وفقط إذا تحققت البنود الآتية:

- a) $Z_i \neq \emptyset ; \forall i \in I$
- b) $Z_i \cap Z_j = \emptyset ; \forall i, j \in I$
- c) $E = \bigcup_{i \in I} Z_i$

إنَّ المجموعات Z_i المكوّنة للتجزئة تُسمّى ذرات التجزئة \mathbb{Z} Atoms of the Partition.

(١٢، ٢، ١، ٤) ملاحظات

١- في الحالة الخاصة عندما تكون $\mathbb{Z} = \{E\}$ ، فعندئذ يُقال عن \mathbb{Z} إنها التجزئة المبتدلة Trivial Partition للمجموعة E .

٢- إذا كانت $E = \Omega$ مجموعة نتائج تجربة عشوائية، وكانت:

$$\mathbb{Z} = \left\{ Z_i ; Z_i \subseteq \Omega , i \in I \right\}$$

تجزئة لـ Ω مع Z_i حوادث من أجل كل $i \in I$ ، فإنَّ \mathbb{Z} تُدعى صفافاً تاماً من الحوادث.

٣- إذا كانت Ω مجموعة نتائج تجربة عشوائية، وكانت Ω منتهية أو غير منتهية ولكنها قابلة للعدّ على الأكثر، فعندئذ:

أ- سنأخذ $\mathcal{A} = 2^\Omega$ على أنه الـ σ -جبر فوق Ω ما لم نشير إلى خلاف ذلك أو يفرض علينا نموذجاً معيّناً من الجبر نتيجة للمسألة التي قيد الدراسة.

ب- يمكننا وبشكل وحيد أن نشكّل جبراً \mathcal{A} فوق Ω على النحو الآتي:

$$\mathcal{A} = \left\{ \emptyset , \sum_{i=1}^n Z_i ; n \in \mathbb{N}_{|I|} \right\}$$

وهذا الجبر \mathcal{A} يُدعى الجبر المولّد من التجزئة \mathbb{Z} ، ويكتب حينئذ $\mathcal{A} = \alpha(\mathbb{Z})$.

في الواقع، إنَّ الطرح السابق قابل للعكس بمعنى أنَّه إذا كان \mathcal{A} جبراً فوق Ω فإنَّه توجد تجزئة وحيدة \mathbb{Z} للمجموعة Ω بحيث تكون ذراتها من \mathcal{A} ، ويكون لدينا في هذه الحالة $\mathcal{A} = \alpha(\mathbb{Z})$.

خلاصة القول:

تحت الفرضيات السابقة يوجد تقابل واحد لواحد بين أسرة كل الجبر فوق Ω وأسرة كل التجزئات للمجموعة Ω .

(١٣, ٢, ١, ٤) أمثلة

- ١- الجبر المبتدل $\mathcal{A} = \{\emptyset, \Omega\}$ يولد من التجزئة المبتدلة $\mathcal{Z} = \{\Omega\}$.
 - ٢- الجبر المولد من حادث $\Omega \supset A$ يولد من التجزئة $\mathcal{Z} = \{A, \bar{A}\}$.
 - ٣- إذا كانت $\Omega = \{\omega_1, \omega_2, \dots, \omega_n\}$ منتهية، فإن الجبر القوي 2^Ω يولد من التجزئة $\mathcal{Z} = \{\{\omega_1\}, \{\omega_2\}, \dots, \{\omega_n\}\}$.
 - ٤- إذا كانت $\Omega = \{\omega_1, \omega_2, \dots, \omega_n, \dots\}$ غير منتهية ولكنها قابلة للعد، فإن الجبر القوي 2^Ω يولد من التجزئة الآتية:
 $\mathcal{Z} = \{\{\omega_1\}, \{\omega_2\}, \dots, \{\omega_n\}, \dots\}$
- يُقدم الجدول الآتي قراءةً توضّح أوجه الاختلاف بين نظرية المجموعات ونظرية الاحتمالات في تفسير بعض الكائنات الرياضية التي تعاملنا معها سابقاً.

الجدول (٤, ٣)

الرمز	التفسير وفقاً لنظرية المجموعات	التفسير وفقاً لنظرية الاحتمالات
ω	عنصر أو نقطة	حادث ابتدائي أو نتيجة تجربة عشوائية
Ω	مجموعة عناصر	مجموعة نتائج تجربة عشوائية أو فضاء الحوادث الابتدائية أو الحادث الأكيد
\emptyset	المجموعة الخالية	الحوادث المستحيل
\mathcal{A}	صف مجموعات، وعندما يكون مُحققاً لشروط الجبر هو جبر لمجموعات	صف مجموعات، وعندما يكون مُحققاً لشروط الجبر هو جبر لحوادث
$A \in \mathcal{A}$	عنصر من صف مجموعات	حادث
\bar{A}	المجموعة المتممة لمجموعة A بالنسبة إلى مجموعة شاملة Ω	الحادث الذي سَيُحقق في حال عدم تحقق الحادث A من فضاء الحوادث الابتدائية Ω
$A \cup B$	مجموعة العناصر التي تنتمي إلى المجموعة A أو إلى B أو إلى كليهما	الحادث الذي يتحقق بتحقق الحادث A أو الحادث B أو تحقق كليهما معاً
$A \cap B$	مجموعة العناصر التي تنتمي إلى كل من المجموعتين A و B معاً	الحادث الذي يتحقق بتحقق الحادثين A و B في آن واحد
$A \setminus B$	مجموعة العناصر التي تنتمي إلى المجموعة A ولا تنتمي إلى المجموعة B	الحادث الذي يتحقق بتحقق الحادث A ولكن دون تحقق الحادث B
$A \Delta B$	مجموعة العناصر التي تنتمي إلى مجموعة A أو إلى B ولكن دون أن تنتمي إلى كليهما	الحادث الذي يتحقق بتحقق الحادث A أو تحقق الحادث B ولكن دون تحققهما معاً

(٣, ١, ٤) تعيين الدالة الاحتمالية:

يُعدّ تعيين الدالة الاحتمالية من أصعب المراحل الثلاث الخاصة بتعيين الفضاء الاحتمالي لتجربة عشوائية، وذلك لأنّ المرحلة الأولى المتمثلة بتعيين فضاء الحوادث الابتدائية Ω ، والثانية المتمثلة بتعيين جبر الحوادث فوق Ω ، ليستا بالأمر الصعب. أما الصعوبة في تعيين الدالة الاحتمالية فتكمن في أكثر من جانب منها:

- ١- كيف يمكننا تعيين احتمال الحادث الابتدائي في تجربة عشوائية ما؟
 - ٢- ما هي الخصائص التي يجب على الدالة تحقيقها حتى تصبح عديمة التناقض لدى تعميمها؟
- في الحقيقة يمكننا الجزم بأنّ الإجابة على السؤال الأول ليس من صلب نظرية الاحتمالات، وذلك لأنّ احتمال حادث ابتدائي متعلق بطبيعة المادة التي تجري عليها التجربة، فعلى سبيل المثال:
- (أ) لو أخذنا تجربة قذف قطعة نقود متوازنة لمرة واحدة فقط، فعندئذ سيكون نسبة ظهور (هذه النسبة سيصبح لها بعد قليل اسم الاحتمال)

كل حادث ابتدائي متعلق بهذه التجربة يساوي $\frac{1}{2} = \frac{1}{|\Omega|}$ ، ولكن في حال ليس لدينا معلومات حول تجانس المادة التي صنعت منها قطعة النقود، فعندئذ لا يمكننا الادعاء أن نسبة ظهور كل حادث ابتدائي متعلق بهذه التجربة يساوي $\frac{1}{2}$ ، فقد يكون مركز ثقل القطعة منحازاً إلى أحد وجهي القطعة بسبب عدم تجانس المادة المكونة للقطعة، ومن ثم يكون للوجه الآخر نسبة أكبر في الظهور للأعلى.

ب) لو أخذنا تجربة قذف قطعة نقود متوازنة لمرة متتاليتين، فعندئذ سيكون نسبة ظهور كل حادث ابتدائي متعلق بهذه التجربة يساوي $\frac{1}{4} = \frac{1}{|\Omega|}$.

ج) لو أخذنا تجربة قذف قطعة نقود متوازنة لـ n مرة متتالية، فعندئذ سيكون نسبة ظهور كل حادث ابتدائي متعلق بهذه التجربة يساوي $\frac{1}{2^n} = \frac{1}{|\Omega|}$.

أما للإجابة على السؤال الثاني فقد بُدلت من أجله محاولات جادة من قبل بعض علماء الرياضيات (وعلماء الاحتمالات على وجه الخصوص)، وقد تراوحت نتائجهم ما بين عدم الدقة حيناً والتخصيص حيناً آخر، إلى أن جاء التعميم في النصف الأول من القرن العشرين (في عام 1933) على يد الرياضياتي الروسي كالموغوراف.

فيما يلي سنقوم بعرض مبسط وموجز لبعض الطرائق التي قُدمت لتعيين الدالة الاحتمالية مع التنويه بعيوب كل من هذه الطرائق.

(١, ٣, ١, ٤) تعيين الدالة الاحتمالية اعتماداً على التكرار النسبي لحادث

لنفترض أننا نقوم بتنفيذ تجربة عشوائية مجموعة نتائجها Ω ، وسنرصدها (أو نراقب) من خلال هذه التجربة تحقق حادث ما A متعلق بهذه التجربة العشوائية، ثم نكرر هذه التجربة وتحت الشروط نفسها عدداً من المرات قدره n ، ولنفترض أن الحادث A قد تحقق m مرة خلال الـ n تجربة، فعندئذ يسمى العدد m **بالتكرار المطلق** Absolut Frequency **للحادث A** ويرمز له بـ $H_n(A)$ ، في حين أن النسبة $\frac{m}{n}$ تدعى **التكرار النسبي** Relative Frequency **للحادث A** ويرمز له بـ $h_n(A)$ ، أي إن:

$$h_n(A) = \frac{m}{n} \quad [4,2]$$

وهكذا نلاحظ أن $H_n(A)$ هو عدد من \mathbb{N}_n ، في حين أن $h_n(A)$ هو عدد من المجموعة $\left\{0, \frac{1}{n}, \frac{2}{n}, \dots, 1\right\}$ ، وعلاوة على ذلك يمكن التحقق وبسهولة من صحة البنود الآتية:

$$١ - \text{لدينا } 0 \leq h_n(A) \leq 1.$$

$$٢ - \text{لدينا } h_n(\Omega) = 1, \text{ وكذلك } h_n(\emptyset) = 0 \text{ دوماً.}$$

$$٣ - \text{من أجل أي حادثين } A \text{ و } B \text{ متعلقين بهذه التجربة لدينا:}$$

$$h_n(A \cup B) = h_n(A) + h_n(B) - h_n(A \cap B)$$

$$٤ - \text{من أجل أي حادثين } A \text{ و } B \text{ متعلقين بهذه التجربة مع } B \supseteq A \text{ يكون لدينا } h_n(B) \geq h_n(A).$$

الآن بفرض أن n قيمة مثبته، فإنه من أجل أي حادث A متعلق بهذه التجربة يمكننا أن نلحقه (نقابله) بعدد غير سالب $h_n(A)$ ، ومن ثم يصبح لدينا دالة P معرفة على أسرة حوادث من Ω (تحقق شروط الجبر على Ω) وقيمها في الفترة $[0, 1]$ كما يلي:

$$P(A) := h_n(A) \quad [4,3]$$

فعندئذ نجد أن الدالة P تحقق الخصائص الآتية:

١- من أجل أي حدث A متعلق بالتجربة العشوائية لدينا $0 \leq P(A) \leq 1$ ، وعلى وجه الخصوص $P(\emptyset) = 0$.

٢- من أجل أي حدثين A و B متنافيين متعلقين بالتجربة العشوائية يكون:

$$P(A + B) = P(A) + P(B)$$

٣- لدينا $P(\Omega) = 1$ ، وذلك لأنه من أجل أي حدث A متعلق بالتجربة العشوائية لدينا:

$$P(\bar{A}) = 1 - P(A) \Rightarrow P(\Omega) = P(\bar{\emptyset}) = 1 - P(\emptyset) = 1$$

إن الدالة P المعرفة آنفاً سُميت **دالة احتمالية**، ولكن نلاحظ أن هذا التعريف للدالة الاحتمالية ليس دقيقاً، وذلك لأنها عرفت من أجل قيمة مُثبتة n ، إذ إنه ما يدرينا أننا سنحصل على القيم لـ $h_n(A)$ نفسها لو أننا أعدنا التجربة عدداً أكبر من المرات؟ عند هذا الاعتراض على تعريف الدالة P قدّم طرح بديل، وهو أن تأخذ نهاية التكرار النسبي لحدث A عندما n تسعى إلى اللانهاية كاحتمال لهذا الحدث، أي أن نضع:

$$P(A) = \lim_{n \rightarrow \infty} h_n(A) \quad [4,4]$$

وهنا جاء الرد بالرفض أيضاً بناءً على نتائج مثال **بيفون-بيرسون** الآتي:

(١, ١, ٣, ١, ٤) مثال (تجربة بيفون-بيرسون Buffon-Pearson Experiment):

لقد قام الرياضياتي والمؤرخ الطبيعي الفرنسي **بوفون** (Georges-Louis de Buffon (1707-1788)، وكذلك الرياضياتي **بيرسون** بدراسة تأثير استقرارية التكرار النسبي في مثال قذف قطعة نقود معدنية متوازنة (أي لكل من الوجهين النصيب نفسه في الظهور)، ورصداً حدث ظهور الصورة (وليكن A)، فكانت نتائجها كما في الجدول الآتي:

الجدول (٤, ٤)

نتائج	عدد الرميات التي نفذت	التكرار المطلق للحدث A	التكرار النسبي للحدث A
بيفون	4040	2048	0.5080
بيرسون	12000	6019	0.5016
بيرسون	24000	12012	0.5005

فلو قمنا بدراسة تقارب متتالية التكرارات النسبية $(h_n(A))_{n \in \mathbb{N}}$ فإننا سنجد أنها متباعدة نحو الـ ∞ (ليست متقاربة)، وذلك لأنه لو افترضنا جدلاً أن المتتالية $(h_n(A))_{n \in \mathbb{N}}$ متقاربة من العدد $h(A) = 0.5$ (التي تعني أن قطعة النقود متوازنة) لوجب أن يكون بحسب تعريف التقارب للمتتاليات العددية الاتي مُحققاً:

من أجل أي $0 < \varepsilon$ يوجد عدد صحيح غير سالب $N(\varepsilon)$ بحيث إنه من أجل كل القيم $N(\varepsilon) < n$ يكون $|h_n(A) - h(A)| < \varepsilon$ ، وهذا غير متوافق مع المثال المعطى، فلو أخذنا على سبيل المثال $\varepsilon = 0.00051$ لوجدنا من التجربة الأخيرة لـ بيرسون ما يلي:

$$|h_n(A) - h(A)| = |0.5005 - 0.5| = 0.0005 < \varepsilon$$

وسنجد منها أن $\frac{1}{\varepsilon} > \frac{10000}{5}$ ، ومن ثم يكون $N(\varepsilon) > 2000$ ، وهذا يعني أنه من أجل $N(\varepsilon) < n = 2000$ يجب أن يكون لدينا $|h_n(A) - h(A)| < \varepsilon$ ، ولكن هذه المتباينة غير مُحققة من أجل تجربة بيفون، وذلك لأنه من أجل $N(\varepsilon) < n = 4040$ لدينا:

$$|h_n(A) - h(A)| = |0.5080 - 0.5| = 0.0080 > \varepsilon = 0.00051$$

وهذا يعني تباعد المتتالية $(h_n(A))_{n \in \mathbb{N}}$ ، ومن ثم لا يجوز لنا أن نأخذ نهاية التكرار النسبي لحدث A كاحتمال لهذا الحدث A .

خلاصة القول:

إن التكرار النسبي لحادث لا يصلح لتعريف دالة احتمالية وذلك لأنه تؤخذ عليه العلتين الآتيتين:
١- إن التكرار النسبي لحادث لا يمكن أن يولد منها سوى متتالية منتهية بحيث إنه لا يمكننا ولا بشكل من الأشكال أن ننظر لتقارب متتالية التكرارات النسبية المستنتجة بمنظور تقارب المتتاليات العددية.

٢- حتى في حال تجاوزنا التحذير السابق وقبولنا بتعريف الاحتمال وفقاً للعلاقة (٤, ٤)، فإنه ليس هناك ما يضمن لنا حتمية تقارب متتالية التكرارات النسبية كما لاحظنا ذلك سابقاً.
على الرغم من ذلك نلاحظ أن التكرار النسبي لحادث A يظهر لنا استقرار قيمة احتمال الحادث، وذلك لأنه يعطينا قيمة تقريبية لاحتمال للحادث (وليست دقيقة)، وهذا يوصلنا إلى فناعة مفادها أن احتمال وقوع حادث ما يمكن أن يميز بعدد وفق منهج ما.
العرض التالي للدالة الاحتمالية قد يكون أكثر فائدة في إعطاء منهج محدد لتعيين الدالة الاحتمالية ولكنه على كل الأحوال ليس بالكافي أيضاً حيث سنلاحظ ذلك جلياً من خلال عرض هذه الطريقة.

(٢, ٣, ١, ٤) تعيين الدالة الاحتمالية اعتماداً على مبدأ لابلاس للحالات متساوية الإمكانية

لقد قام الرياضياتي الفرنسي لابلاس (Pierre-Simon, marquis de Laplace (1749-1827 بمحاولة جادة لتعريف الاحتمال لحادث من خلال حالة خاصة عندما تكون مجموعة نتائج التجربة العشوائية Ω منتهية، وكذلك لجميع نتائج التجربة العشوائية النصيب نفسه في الظهور. حيث لاحظ من مواقف عملية أنه يمكن الاستفادة من استخدام خاصية التجانس للمادة التي تجرى عليها التجربة (مثل قطعة نقود مصنعة من مادة متجانسة)، وهي تقتضي أن يصبح لجميع النتائج النصيب نفسه في الظهور.

فلو افترضنا أن $\Omega = \{\omega_1, \omega_2, \dots, \omega_n\}$ مع $n \in \mathbb{N}$ مثبت، فإنه إذا كان احتمال الحادث الابتدائي ω_i هو p_i من أجل كل $i \in \mathbb{N}_n$ ، فعندئذ سيكون لدينا $p_1 = p_2 = \dots = p_n = 1/n$ ، ومن ثم يكون احتمال أي حادث A متعلق بالتجربة العشوائية يساوي النسبة $\frac{|A|}{|\Omega|} = \frac{|A|}{n}$ ، وهذا يعني أنه يمكن تعريف دالة P على أسرة حوادث متعلقة بهذه التجربة العشوائية (تحقق شروط الجبر على Ω) من خلال العلاقة الآتية:

$$P(A) = \frac{|A|}{|\Omega|} \quad [4.5-a]$$

وقد صاغها لابلاس على النحو الآتي أيضاً:

$$\text{احتمال الحادث الذي قيد الدراسة} = \frac{\text{عدد الحالات الملائمة لهذا الحادث}}{\text{عدد الحالات الممكنة للتجربة}}$$

ومن ثم يكون:

$$P(A) = \frac{|A|}{|\Omega|} \quad [4.5-b]$$

وهنا نلاحظ أن الدالة P المعطاة من خلال العلاقة [4.5-a] (أو [4.5-b]) تحقق البنود الآتية:

١- من أجل أي حادث A متعلق بالتجربة العشوائية يكون $0 \leq P(A) \leq 1$ ، وعلى وجه الخصوص لدينا $P(\emptyset) = 0$ دوماً.

٢- من أجل أي حادثين A و B متنافيين متعلقين بالتجربة العشوائية يكون لدينا $P(A + B) = P(A) + P(B)$.

٣- لدينا $P(\Omega) = 1$.

وقد أطلق على P اسم الدالة الاحتمالية، والعلاقة الأخيرة [4.5-b] التي وضعها لابلاس أطلق عليها اسم مبدأ لابلاس للحالات المتساوية الإمكانية، وعُرفت فيما بعد باسم التعريف التقليدي للاحتتمال Classical Definition of Probability.

إنَّ التعامل مع هذا التعريف للاحتمال سيقود المرء في كثير من الحالات إلى استخدام التحليل التوافقي (استخدام التباديل، الترتيب والتوافيق) لحل المسائل، ومن ثمَّ سنلاحظ أنَّ التحليل التوافقي سيقوم بدور مهم في الحساب الاحتمالي لمسائل تتوافق وحالتنا هذه. هذا من جانب، ومن جانب آخر يجب على المرء ألا يتجاوز فرضيات هذا التعريف إذ إنه يصبح عديم الفائدة عندما يكون فضاء الحوادث الابتدائية غير منته (وذلك لأنَّ احتمال أي حادث سوف يسمى إلى الصفر) أو عندما يكون للحوادث الابتدائية احتمالات مختلفة.

(١, ٢, ٣, ١, ٤) أمثلة

١- لنفرض أنَّه لدينا صندوقان I و II يحويان كرات متماثلة بألوان مختلفة، وبحيث يحوي الصندوق الأول I على كرتين بيضاء اللون وكرة سوداء بينما يحوي الصندوق الثاني II كرة بيضاء وكرة سوداء وأخرى زرقاء. الآن نقوم بخلط الكرات في الصندوق الأول جيداً ومن ثمَّ نسحب (سحب عشوائي) كرة من هذا الصندوق ونضعها في الصندوق الثاني دون رؤيتها، وبعد ذلك نقوم بخلط الكرات في الصندوق الثاني جيداً ومن ثمَّ نسحب كرة من هذا الصندوق. عندئذ لنحسب احتمال أن تكون الكرة المسحوبة أخيراً ذات لون أسود.

الحل: نلاحظ أولاً أنَّ لجميع الحوادث الابتدائية الناتجة عن هذه التجربة النصيب نفسه في الظهور، وكذلك فضاء الحوادث الابتدائية لهذه التجربة منته، فلو رمزنا للكرتين البيضاويين في الصندوق الأول بـ W_{11} و W_{12} وللكرة السوداء في هذا الصندوق بـ B_{11} بينما سنرمز للكرة البيضاء والسوداء والزرقاء في الصندوق الثاني على الترتيب بـ W_{21} , B_{21} , BL ، فعندئذ يكون لدينا:

$$\Omega = \left\{ (W_{11}, W_{11}), (W_{11}, W_{21}), (W_{11}, B_{21}), (W_{11}, BL), (W_{12}, W_{12}), (W_{12}, W_{21}), (W_{12}, B_{21}), (W_{12}, BL), (B_{11}, B_{11}), (B_{11}, B_{21}), (B_{11}, W_{21}), (B_{11}, BL) \right\}$$


حيث ترمز المركبة الأولى من الثنائية إلى نتيجة السحب الأول بينما ترمز المركبة الثانية من الثنائية إلى نتيجة السحب الثاني، وبفرض أنَّ A هو حادث سحب كرة سوداء من الصندوق الثاني بعد إضافة كرة إليه من الصندوق الأول فإنه يمكننا أن نكتب:

$$A = \{ (W_{11}, B_{21}), (B_{11}, B_{11}), (W_{12}, B_{21}), (B_{11}, B_{21}) \}$$

ومن ثمَّ بحسب مبدأ لابلاس في الاحتمالات يكون لدينا:

$$P(A) = |A| / |\Omega| = 4 / 12 = 1/3$$

٢- لنفترض أنه لدينا بطاقات لعب Playing Cards مكون من 52 بطاقة ولها العرض الآتي:



لدينا أربعة أنواع من البطاقات هي: ♠، ♥، ♦، و♣ وتُدعى دینار Diamond، قلب Heart، بستیوني Spade و زهر Club على الترتيب.



قمنا بخلط البطاقات جيداً ومن ثم سحبنا ست بطاقات دفعة واحدة، فما هو احتمال أن نحصل على العرض الجانبي لهذه البطاقات؟

الحل: نعلم أنه يوجد أربع بطاقات من كل نموذج ولونان وأربعة أصناف في هذا النوع من البطاقات. عندئذ يمكننا اختيار بطاقة من هذه البطاقات المماثلة لها بعدد من الطرائق يساوي:

$$\binom{4}{1} = \frac{4!}{1! \cdot 3!} = 4$$

ومن جهة أخرى بحسب المبدأ الأساسي في العدّ (قاعدة الضرب - انظر الملحق A-) يمكننا اختيار هذه البطاقات الست من بين مثيلاتها بعدد من الطرائق يساوي:

$$\binom{4}{1} \cdot \binom{4}{1} \cdot \binom{4}{1} \cdot \binom{4}{1} \cdot \binom{4}{1} \cdot \binom{4}{1} = \left(\binom{4}{1} \right)^6 = 4^6 = 4096$$

ومنه بفرض أن A هو حادث الحصول على البطاقات الست المعروضة سابقاً، فإن عدد الحالات الملائمة لهذا الحادث يساوي 4096، وأما عدد الحالات الممكنة للتجربة، وهو عدد الطرائق لسحب 6 بطاقات دفعة واحدة من 52 بطاقة، فإنه يساوي:

$$\binom{52}{6} = \frac{52!}{6! \cdot 46!} = 20358520$$

ومنه بحسب مبدأ لابلاس في الاحتمالات يكون للاحتمال المطلوب القيمة الآتية:

$$P(A) = \frac{4096}{20358520} = 0.000201$$

٣- لنفترض أنه لدينا بطاقات لعب مكوّنة من 52 بطاقة، قمنا بخلط البطاقات جيداً ومن ثم سحبنا ثلاث بطاقات في آن واحد،

فما هو احتمال أن تكون البطاقات الثلاث:

١- جميعها واحداث \spadesuit Aces؟

٢- جميعها ألماسات \heartsuit diamonds؟

٣- من أصناف مختلفة؟

٤- من ألوان مختلفة؟

الحل: من أجل الإجابة على هذه الأسئلة لنرمز بـ:

A لحادث الحصول على ثلاث واحداث لدى عملية السحب.

B لحادث الحصول على بطاقات ألماس لدى عملية السحب.

C لحادث الحصول على بطاقات من أنواع مختلفة لدى عملية السحب.

D لحادث الحصول على بطاقات من ألوان مختلفة لدى عملية السحب.

عندئذ يكون لدينا:

$$P(A) = \frac{|A|}{|\Omega|} = \frac{\binom{4}{3}}{\binom{52}{3}} = 0.00018 \quad \& \quad P(B) = \frac{|B|}{|\Omega|} = \frac{\binom{13}{3}}{\binom{52}{3}} = 0.0129$$

$$P(C) = \frac{|C|}{|\Omega|} = 4 \frac{\binom{13}{1} \cdot \binom{13}{1} \cdot \binom{13}{1}}{\binom{52}{3}} = 0.3976 \quad \& \quad P(D) = P(\emptyset) = 0$$

وذلك لأنه لدينا لونان فقط فإن D لا تحوي أية نتيجة، أي إن $D = \emptyset$.

(٣, ٣, ١, ٤) تعيين الدالة الاحتمالية هندسياً

لقد لاحظنا أن التعريف التقليدي للاحتمال قابل للتطبيق في حالات خاصة فقط، ولذلك حاول بعض الرياضياتيين تقديم تعريف للاحتمال وفق عرض هندسي من خلال تمثيل الحوادث بأشكال هندسية مناسبة، اعتقاداً منهم أنهم قد تجاوزوا السلبيات التي اعترضت طريقة التكرار النسبي والتعريف التقليدي للاحتمال فكانت الانطلاقة على النحو الآتي:

إن أية نتيجة للتجربة العشوائية يمكن أن تُفسَّر (ومن أسس هندسية) على أنها قذف عشوائي لنقطة على مجموعة أساس Ω من الفضاء الإقليدي R^n ، وهنا يجب أن يفهم من كلمة عشوائي ما يلي:

١- إن النقطة المقذوفة يمكن لها أن تقع (تنطبق) على أي نقطة من Ω .

٢- الحوادث التي لها القياس نفسه (الطول نفسه - المساحة نفسها - الحجم نفسه ...) سيكون لها النصيب نفسه في الظهور. عندئذ يُحسب احتمال حادث متعلق بالتجربة العشوائية من خلال العلاقة الآتية:

$$\text{احتمال الحادث الذي قيد الدراسة} = \frac{\text{قياس الشكل الممثل لهذا الحادث}}{\text{قياس } \Omega}$$

ومن ثم يمكن حساب احتمال حادث A متعلق بالتجربة من خلال العلاقة الآتية:

$$P(\Omega) = \frac{\text{قياس الشكل الممثل لهذا الحادث } A}{\text{قياس } \Omega} = \frac{m(A)}{m(\Omega)} \quad [4,6]$$

وهذه العلاقة اشتهرت باسم **التعريف الهندسي للاحتمال** Geometric Definition of Probability.

(١, ٣, ٣, ١, ٤) ملاحظات

١- إن الحوادث التي لها حيز ذو بُعد أصغر من بُعد الحيز الأساس Ω يكون لها قياس يساوي الصفر (قياسها معدوم)، ومن أمثال هذه الحوادث: نقطة في مستقيم - مستقيم في مستو - مستو في الفراغ الثلاثي وما فوق أو...

٢- إن احتمال حادث A يكون مستقلاً عن الطول والشكل الخاص بهذا الحادث في Ω ، وذلك لأن احتمال هذا الحادث هو نسبة قياس هذا الحيز إلى قياس Ω . بمعنى آخر، إن احتمال حادث A من Ω يكون مساوياً لسلوك النسبة بين الحيز الملائم للحادث A وبين الحيز الذي يشغله Ω .

٣- نلاحظ أن الدالة P المعطاة من بالعلاقة [4.6] تُحقق البنود الآتية:

أ- من أجل أي حادث A متعلق بالتجربة العشوائية لدينا $0 \leq P(A) \leq 1$ ، وعلى وجه الخصوص $P(\emptyset) = 0$ دوماً، علماً أن الحادث المستحيل \emptyset هنا هو ذلك الحادث الذي لا يحوي أية نتيجة من نتائج التجربة العشوائية وبُعد الحيز الذي يشغله يساوي بُعد الحيز الأساس Ω أيضاً.

ب من أجل أي حادثين A و B متنافيين متعلقين بهذه التجربة يكون لدينا $P(A + B) = P(A) + P(B)$.


٤- إن الحوادث التي لها حيز ذو بُعد أصغر من بُعد الحيز الأساس Ω يكون لها قياس يساوي الصفر كما ذكرنا ذلك سابقاً، ولكنها ليست حوادث مستحيلة، وتسمى **حوادث شبه مستحيلة** Almost Impossible Events.

بناءً على ما سبق تم التعامل مع الدالة P كدالة احتمالية، وهنا نلاحظ أن هذا العرض للحساب الاحتمالي يبيدي انسجاماً وتطابقاً مع التعريف التقليدي للاحتمال إذا ما أخذنا بالحسبان أن الحوادث التي لها حيز مشغول بالقياس نفسه يكون لها الاحتمال نفسه في الظهور (يقابل في التعريف التقليدي للاحتمال أن لجميع الحوادث الابتدائية النصيب نفسه في الظهور)، إلا أن التعميم في هذه الطريقة يكمن في أن

عدد الحوادث الابتدائية يمكن أن يكون غير منته.

المثال الآتي يُعدُّ من الأمثلة النموذجية على الحساب الاحتمالي باستخدام المفهوم الهندسي للاحتمال.

(٢, ٣, ٣, ١, ٤) مثال التقاء شخصين



الشكل (١, ٤)

اتفق شخصان على الالتقاء في مكان مُحدَّد وخلال مُدَّة ساعة معيَّنة بحيث إنَّه إذا قلم أحدهما إلى المكان المُحدَّد خلال هذا الموعد ولم يجد زميله فإنَّه ينتظر لمدة 15 دقيقة فقط، ثمَّ يغادر المكان مباشرة، والسؤال المطروح هو: ما هو احتمال التقاء الشخصين؟

الحل: من أجل ذلك لنأخذ الجملة المتعامدة XOY حيث المحور OX يرمز للزمن الخاص بالشخص الأول، وأما OY فإنَّه يرمز للزمن الخاص بالشخص الآخر، فيكون ل Ω الحيز المعين بالمربع $[0, 60] \times [0, 60]$ والموضح في الشكل الجانبي آنفاً، أي إنَّ $\Omega = [0, 60] \times [0, 60]$ ، ومن ثمَّ يكون لدينا:

$$m(\Omega) = 60 \times 60 = 3600$$

وأما الحادث A الذي يعبر عن التقاء الشخصين فهو الحيز:

$$A = \{ (x, y) \in \mathbb{R}^2 \mid 0 < x < 60 \text{ \& } 0 < y < 60 \text{ with } |x - y| \leq 15 \}$$

وقياس الحيز الذي يشغله يساوي:


$$m(A) = m(\Omega) - 2 \frac{(45)(45)}{2} = 1575$$

ومن ثمَّ ينتج لدينا أنَّ الاحتمال المطلوب يساوي:

$$P(A) = \frac{m(A)}{m(\Omega)} = 0.4375$$

في هذا الجانب نشير إلى أنَّ التعريف الهندسي للاحتمال قد لقي في بدايات تقديمه أنواعاً من سوء الفهم والخطأ في الاستخدام، وإلى النقد اللاذع الذي دفع بعضهم إلى رفض الحساب الاحتمالي كفرع من الفروع العلمية، وذلك عندما قام البعض بعرض بعض المسائل التي نتج عنها حلول مختلفة وفقاً لطرائق مختلفة للحل على حدِّ زعمهم، حيث يجب أن تكون نتيجة الحل ثابتة بغض النظر عن الطريقة المتبعة في الحل. في الحقيقة إنَّ هذه النتائج المختلفة لحلول بعض المسائل لا يعود في حقيقة الأمر إلى تناقض في المفهوم الهندسي للاحتمال، وإنَّما يعود إلى عدم وجود ضوابط دقيقة للمسائل المطروحة آنذاك، فعلى سبيل المثال قام الرياضياتي والفيلسوف البريطاني **برتراند** (1872-1970) Arthur William Russell Bertrand بتقديم مثال في عام 1889، ويُعرف هذا المثال باسم **مُحيرة برتراند**.

(٣, ٣, ٣, ١, ٤) مسألة (مُحيرة برتراند Bertrand Paradox)



الشكل (٢, ٤.١)

نقوم بسحب عشوائي لوتر في دائرة نصف قطرها r ، فما هو احتمال أن يكون طول هذا الوتر أكبر أو يساوي طول ضلع مثلث متساوي الأضلاع مرسوم داخل هذه الدائرة؟


لقد قدَّم **برتراند** ثلاث طرائق لحل هذه المسألة هي كالآتي:

الطريقة الأولى: نعطي توجيهاً للوتر، وسنفترض أنَّ الوتر سيتحرك بشكل عمودي على قطر هذه الدائرة (انظر الشكل الجانبي)، فعندئذ يفرض A هو الحادث الذي يعبر عن الحالة التي يكون فيها طول الوتر أكبر أو يساوي طول ضلع مثلث متساوي الأضلاع مرسوم داخل

هذه الدائرة، فإنَّ هذا الحادث يوافق الحيز المحصور بالمستقيمين $x = \frac{r}{2}$ و $x = \frac{3r}{2}$ ، ومن ثمَّ ينتج لدينا:

$$P(A) = \frac{m(A)}{m(\Omega)} = \frac{r}{2r} = \frac{1}{2}$$


وهكذا نلاحظ أنه فُسر مفهوم السحب العشوائي على أنه قذف نقطة على الفترة $[0, 2r]$ ، وهذا يعني أنه لدينا $\Omega = [0, 2r]$.



الطريقة الثانية: في هذه الطريقة ثبت إحدى نهايتي الوتر على طرف الدائرة وترك الوتر يتأرجح بشكل عشوائي داخل هذه الدائرة (انظر الشكل الجانبي)، فعندئذ يكون الحيز الموافق للحادث A هو الحيز الموافق لزاوية محيطية قدرها $\frac{\pi}{3}$ ومجاورة لزاوية قدرها $\frac{\pi}{3}$ مع المماس للدائرة عند نقطة تثبيت الوتر مع الدائر، وهكذا ينتج لدينا:

$$P(A) = \frac{m(A)}{m(\Omega)} = \frac{\frac{\pi}{3}}{\pi} = \frac{1}{3}$$

فلاحظ هنا أنه فُسر مفهوم السحب العشوائي على أنه قذف نقطة على الفترة $[0, \pi]$ ، ومن ثم أصبح لدينا في هذه الحالة $\Omega = [0, \pi]$.



الطريقة الثالثة: من المعلوم أن الوتر يمكن أن يعين وبشكل وحيد من خلال نقطة منتصف الوتر، ومن ثم بفرض أن ρ هو بُعد الوتر عن مركز الدائرة و ℓ هو طول الوتر (انظر الشكل الجانبي)، فإنه سيكون لدينا $\ell = 2\sqrt{r^2 - \rho^2}$ ، ومن ثم الحادث A يتحقق إذا كان $\sqrt{3} \cdot r \leq \ell$ ، وهذا يعني أن الحادث A سيتحقق إذا كان $\rho \geq 0.5r$ ، ومن ثم يكون لدينا:

$$P(A) = \frac{m(A)}{m(\Omega)} = \frac{\pi \rho^2}{\pi r^2} = \frac{\pi \left(\frac{r}{2}\right)^2}{\pi r^2} = \frac{1}{4}$$

وفي هذه الطريقة نلاحظ أنه فُسر السحب العشوائي للوتر على أنه قذف نقطة على سطح دائرة نصف قطرها r ، وهذا يعني أن مجموعة نتائج التجربة هي:

$$\Omega = \{ (x, y) \in \mathbb{R}^2 \mid x^2 + y^2 \leq r^2 \}$$

هكذا نلاحظ أنه حصل على ثلاث قيم لاحتمال الحادث المفروض A ، وأن كل طريقة أعطت قيمة مختلفة عن الأخرى، إن السبب في ذلك يعود لتفسيرات مختلفة لمفهوم السحب العشوائي للوتر وليس بسبب خلل في التعريف الهندسي للاحتمال. إذ إنه فُسر السحب العشوائي في الطريقة الأولى للحل على أنه قذف نقطة على فترة طولها $2r$ وكانت مجموعة نتائج التجربة العشوائية وفقاً لهذا الطريقة هي $\Omega = [0, 2r]$ ، وأما في الطريقة الثانية للحل فقد فُسر السحب العشوائي للوتر على أنه قذف نقطة على فترة طولها π وكانت مجموعة نتائج التجربة العشوائية وفقاً لهذا الطريقة هي $\Omega = [0, \pi]$ ، وأخيراً فُسر السحب العشوائي للوتر في الطريقة الثالثة للحل على أنه قذف نقطة على سطح دائرة نصف قطرها r وكانت مجموعة نتائج التجربة العشوائية وفقاً لهذه الطريقة هي:

$$\Omega = \{ (x, y) \in \mathbb{R}^2 \mid x^2 + y^2 \leq r^2 \}$$

وبذلك نجد أنه لم يُحدد مفهوم السحب العشوائي للوتر بشكل تام وترك ليستخدم دون ضوابط، ومن ثم فإن الحلول الثلاثة السابقة ليست حلولاً للمسألة المطروحة، وإنما هي حلول لثلاث مسائل مختلف بعضها عن بعض الآخر، وأن المسألة المطروحة نفسها هي مسألة غير قابلة للحل ما لم يُحدد وبدقة ما يعنيه بالسحب العشوائي للوتر (كيف سيتم سحب الوتر؟).

(٤, ٣, ١, ٤) عيوب التعريف الهندسي للاحتمال

إذن، وكما لاحظنا فإن استخدام المفهوم الهندسي للاحتمال ليس بالأمر السهل ويخفي في جنباته العديد من العيوب، ولكن وفقاً لمعايير شديدة تعتمد في جانب كبير منها على نظرية القياس أمكن توليد فرع من نظرية الاحتمالات يُعرف باسم **الهندسة العشوائية** Stochastic Geometry، ولهذا العلم تطبيقات عملية واسعة في مجال تقنية الاتصالات والتصوير الفضائي (الاستطلاع). أما أبرز عيوب المفهوم الهندسي للاحتمال فهي:

- ١- صعوبة إيجاد ضوابط دقيقة لمفهوم العشوائية في مجال الهندسة.
- ٢- صعوبة تعيين الشكل الهندسي الموافق للحدث.
- ٣- صعوبة العمليات الحسابية باستخدام الهندسة في الحالة العامة.

خلاصة القول:

وجدنا مما سبق أن كل طريقة من الطرائق السابقة المستخدمة في تعيين الدالة الاحتمالية تعاني من عيوب ومساوئ لا يمكن تجنبها وفقاً للأسس المتبعة في هذا التعيين، فعلى سبيل المثال يصادفنا في كثير من الأحيان تجارب عشوائية ذات عدد غير منته من النتائج، لا بل قد تكون مجموعة نتائج التجربة غير قابلة للعد أيضاً، كأن تكون Ω مساوية لفترة من \mathbb{R} أو لمجال من \mathbb{R}^n ، وفي هذه الحالة لا يمكننا النظر إلى جميع عناصر 2^Ω على أنها حوادث، إذ إنه أثبت وجود مجموعات من $2^\mathbb{R}$ لا يمكن النظر إليها كحوادث، ومنها على سبيل المثال لا الحصر المجموعات غير البوريلية. كذلك من الممكن أن يكون لدينا حوادث مركبة لعدد غير منته من الحوادث، ومن ثم مفهوم الجبر يصبح غير ذي جدوى ونكون مضطرين للتعامل مع مفهوم الـ σ -جبر. لذلك كان من الضرورة البحث في منهج شمولي لتعيين الدالة الاحتمالية بحيث يجنبنا التناقضات التي يمكن أن تظهر لنا عند التعميم، وهذا يعني إعطاء الدالة الاحتمالية شروطاً محددة تستجيب لمتطلبات الحالات العامة في الدراسات الاحتمالية التي يمكن أن تصادفنا، وهذا ما تقدمه لنا الفقرة التالية.

(٤, ٣, ١, ٤) تعيين الدالة الاحتمالية وفقاً لمنهج رياضي مجرد

من أجل إعطاء الدالة الاحتمالية مميزات شمولية (عامة) وضعت أسس رياضية مجردة مبنية على مجموعة من المسلمات لبناء الفضاء الاحتمالي من أجل أية تجربة عشوائية، وهذه المسلمات هي:

المسألة الأولى: مجموعة نتائج التجربة العشوائية Ω ليست خالية، أي إن $\Omega \neq \emptyset$ ، وهذه الخاصية مثبتة دوماً.

المسألة الثانية: صف الحوادث المعتمد $\mathcal{A} \subseteq 2^\Omega$ غير خال، وبحيث يكون من نوع الـ σ -جبر فوق Ω .

المسألة الثالثة: الدالة الاحتمالية P تُعرّف على \mathcal{A} كدالة حقيقية غير سالبة، وبحيث تُحقق ما يلي:

- ١- يجب أن يكون $P(\emptyset) = 0$. إن هذا الشرط (والذي هو الشرط الأول من تعريف القياس Measure- في نظرية القياس-) يعني أن الدالة الاحتمالية P ليست مبتذلة، بمعنى أنه يوجد على الأقل حادث $A \in \mathcal{A}$ بحيث يكون $P(A) > 0$ ، ولكن يجب الانتباه هنا بأن هذا الشرط لا يعني أن الحادث المستحيل هو الحادث الوحيد في \mathcal{A} الذي من أجله $P(\emptyset) = 0$ ، إذ إنه من الممكن أن يوجد حادث $A \in \mathcal{A}$ أو أكثر من أجله لدينا $P(A) = 0$ أيضاً، وأمثلة هذه الحوادث تُدعى **حوادث شبه مستحيلة** (كما ذكرنا ذلك سابقاً).

٢- من أجل أي متتالية حوادث $(A_n)_{n \in \mathbb{N}}$ من \mathcal{A} عناصرها متنافية متنى متنى (أي إن $A_i \cap A_j = \emptyset$ لأي $i \neq j$) يكون لدينا:

$$P\left(\sum_{n=1}^{\infty} A_n\right) = \sum_{n=1}^{\infty} P(A_n) \quad [4,7]$$

وهذا الشرط الأخير يوضح لنا بجلاء ضرورة أن يكون جبر الحوادث \mathcal{A} من نوع σ -جبر ولا يكفي أن يكون جبراً فقط.

٣- يجب أن يكون $P(\Omega) = 1$ ، وهنا يجب الانتباه إلى أن هذا الشرط لا يعني أن الحادث الأكيد هو الحادث الوحيد في \mathcal{A} الذي من أجله $P(\Omega) = 1$ ، إذ إنه من الممكن أن يوجد حادث $A \neq \Omega$ من أجله لدينا $P(A) = 1$ أيضاً، وأمثلة هذا الحادث A تُدعى **حوادث شبه أكيدة** Almost Certainly Events.

(١, ٤, ٣, ١, ٤) ملاحظات:

١- إن الثنائية $[\Omega, \mathcal{A}]$ التي عناصرها مُحَقَّقة للمسلمات الأولى والثانية تُدعى **فضاءً مقيساً** (أو فضاءً قياساً أو فضاءً قابلاً للقياس) Measurable Space.

٢- إن الدالة P المُحَقَّقة للشرطين الأول والثاني من المسلمات الثلاثة تُدعى **قياساً** فوق (أو على) الفضاء المقيس $[\Omega, \mathcal{A}]$.

٣- إن القياس P والمُحَقَّق للشرط الثالث من المسلمات الثلاثة يُدعى **قياساً احتمالياً** على الفضاء المقيس $[\Omega, \mathcal{A}]$.

٤- إن الثلاثية $[\Omega, \mathcal{A}, P]$ التي عناصرها مُحَقَّقة للمسلمات الثلاث السابقة تُدعى **فضاءً احتمالياً** Probability Space.

٥- في الحالة الخاصة عندما تكون $\Omega = \mathbb{R}^n$ مع $n \in \mathbb{N}$ مثبت و $\mathbb{R}^1 = \mathbb{R}$ فإننا سنرمز للـ σ -جبر على \mathbb{R}^n بالرمز \mathcal{B} مع $\mathcal{B}^1 := \mathcal{B}$ الذي يُطلق عليه اسم **الحقل البوريلي** Borel Field، وأما عناصر \mathcal{B}^n فيُطلق عليها اسم **مجموعات بوريلية** Borel Sets، وينظر إليها كحوادث.

٦- في الحالة الخاصة عندما تكون $\Omega = \{\omega_1, \omega_2, \dots, \omega_n\}$ مجموعة منتهية، فإنه يمكننا تعيين الدالة الاحتمالية P انطلاقاً من معرفة احتمالات الحوادث الابتدائية، وذلك من خلال تعريف دالة حقيقية غير سالبة Q على أسرة كل الحوادث البسيطة في \mathcal{A} كما يلي:

$$Q : \{\{\omega_1\}, \{\omega_2\}, \dots, \{\omega_n\}\} \longrightarrow [0, \infty) \\ \{\omega_i\} \mapsto Q(\{\omega_i\}) := p_i \quad ; i \in \mathbb{N}_n$$

أي إن p_i هو احتمال الحادث الابتدائي ω_i الذي يفترض أن يكون معلوماً وبحيث يكون $\sum_{i=1}^n p_i = 1$ ، وبعد ذلك يمكننا أن نُعرِّف احتمال أي حادث A من خلال العلاقة الآتية:

$$P(A) = \sum_{\omega \in A} Q(\{\omega\}) = \sum_{\substack{i=1 \\ \omega_i \in A}}^n Q(\{\omega_i\}) \quad [4,8]$$

تطبيقات على هذه الطريقة تجدها في الأمثلة (٥, ٤, ١, ٤) القادمة.

(٤, ١, ٤) خصائص الدوال الاحتمالية Characteristics of Probability Functions

إن المبرهنات الآتية التي سنقدمها دون برهان تعرض لنا بعض الخصائص البسيطة للدالة الاحتمالية، ولكنها مهمة في إطار دراستنا هذه.

(١, ٤, ١, ٤) مبرهنة

ليكن $[\Omega, \mathcal{A}, P]$ فضاءً احتمالياً، فعندئذ:

١- من أجل أي حادث A من \mathcal{A} يكون لدينا $P(\bar{A}) = 1 - P(A)$.

٢- من أجل أي حادثين A و B من \mathcal{A} مع $B \supset A$ سيكون $P(B) \geq P(A)$ ، وهذه الخاصية تُعرِّف باسم **خاصية الاطراد** Monotone Property للقياس الاحتمالي P ، وعلاوة على ذلك يكون لدينا:

$$P(B \setminus A) = P(B) - P(A)$$

٣- من أجل أية متتالية منتهية من الحوادث A_1, A_2, \dots, A_n عناصرها من \mathcal{A} يكون:

$$P\left(\bigcup_{k=1}^n A_k\right) = \sum_{k=1}^n P(A_k) - \sum_{i < j} P(A_i \cap A_j) + \sum_{i < j < k} P(A_i \cap A_j \cap A_k) \pm \dots + (-1)^{n-1} P(A_1 \cap A_2 \cap \dots \cap A_n) \quad [4,9]$$

والذي يُدعى **قانون الجمع** Addition Law في الاحتمالات، حيث نجد:

أ- من أجل $n = 2$ يصبح للعلاقة السابقة [4,9] العرض الآتي:

$$P(A_1 \cup A_2) = P(A_1) + P(A_2) - P(A_1 \cap A_2)$$

ب- من أجل $n = 3$ يصبح للعلاقة السابقة [4,9] العرض الآتي:

$$P(A_1 \cup A_2 \cup A_3) = P(A_1) + P(A_2) + P(A_3) - P(A_1 \cap A_2) - P(A_1 \cap A_3) - P(A_2 \cap A_3) + P(A_1 \cap A_2 \cap A_3)$$

٤- لتكن $(A_n)_{n \in \mathbb{N}}$ متتالية غير منتهية من الحوادث عناصرها من \mathcal{A} ، فعندئذ:

أ- إذا كانت $A_1 \supseteq A_2 \supseteq A_3 \supseteq \dots$ (أي **المتتالية المفترضة غير متناقصة**) فإنه سيكون لدينا:

$$P\left(\bigcup_{i=1}^{\infty} A_n\right) = \lim_{n \rightarrow \infty} P(A_n)$$

وتُعرف هذه خاصية باسم **الاستمرار من الأدنى** Continuous from Below للقياس الاحتمالي P .

ب- إذا كانت $A_1 \supseteq A_2 \supseteq A_3 \supseteq \dots$ (أي **المتتالية المفترضة غير متزايدة**) فإنه سيكون لدينا:

$$P\left(\bigcap_{n=1}^{\infty} A_n\right) = \lim_{n \rightarrow \infty} P(A_n)$$

وتُعرف هذه خاصية باسم **الاستمرار من الأعلى** Continuous from Above للقياس الاحتمالي P ، أي إن القياس الاحتمالي P يحقق خاصية الاستمرار من الأعلى أيضاً.

إذاً، فالقياس الاحتمالي P يحقق خاصيتي الاستمرار من الأدنى والأعلى، ولذلك يُقال عنه إنه **مستمر** Continuous.

(٢, ٤, ١, ٤) تعريف قياس ديراك Dirac Measure

ليكن Ω فضاء الحوادث الابتدائية لتجربة عشوائية ما، و \mathcal{A} هو σ -جبر فوق Ω . الآن من أجل $\omega \in \Omega$ سنأخذ δ_ω دالة حقيقية مُعرّفة على \mathcal{A} كما يلي:

$$\mathcal{A} \ni A \mapsto \delta_\omega(A) = \begin{cases} 0 & \text{for } \omega \notin A \\ 1 & \text{for } \omega \in A \end{cases} \quad [4,10]$$

ويدعى $\delta_\omega(\bullet)$ **قياس ديراك** المُركّز على ω (نسبة إلى الفيزيائي النظري الإنكليزي ديراك (Paul Adrien Maurice Dirac (1902–1984)). في الواقع يلعب هذا القياس دوراً مهماً جداً في صياغة العلاقات للقياسات الاحتمالية في التوزيعات المتقطعة، وهذا ما تظهره لنا المبرهنة الآتية.

(٣, ٤, ١, ٤) مبرهنة

ليكن $[\Omega, \mathcal{A}, P]$ فضاءً احتمالياً، فإذا كان فضاء الحوادث الابتدائية Ω منتهياً أو غير منتهٍ ولكن قابل للعدّ، فعندئذ سيكون للقياس الاحتمالي P العرض الآتي:

$$P(A) = \sum_{\omega \in \Omega} P(\{\omega\}) \delta_{\omega}(A) \quad ; \forall A \in \mathcal{A} \quad [4,11]$$

علماً أنَّ $P(\{\omega\})$ هو احتمال الحادث الابتدائي ω الذي يجب أن يكون معلوماً.

(٤, ١, ٤, ٤) ملاحظات

١- من تعريف قياس ديراك نلاحظ أنَّه من أجل كل $\omega \in \Omega$ ما يلي محققاً:

أ) لدينا $\delta_{\omega}(\emptyset) = 0$.

ب) من أجل أي متتالية حوادث $(A_n)_{n \in \mathbb{N}}$ من \mathcal{A} عناصرها متنافية مثني مثني يكون لدينا:

$$\delta_{\omega} \left(\sum_{n=1}^{\infty} A_n \right) = \sum_{n=1}^{\infty} \delta_{\omega}(A_n)$$

ج) لدينا $\delta_{\omega}(\Omega) = 1$.

وبالتالي من أجل أي $\omega \in \Omega$ مثبت لدينا $[\Omega, \mathcal{A}, \delta_{\omega}]$ هو فضاء احتمالي أيضاً.

٢- بفرض أنَّ فضاء الحوادث الابتدائية Ω منته أو غير منته ولكن قابل للعد، فعندئذ يكون $\sum_{\omega \in \Omega} P(\{\omega\}) = 1$ ، ولإثبات ذلك سنفترض أنَّ $\mathcal{Z} = \{Z_i ; i \in I, I \text{ finite}\}$ تجزئة للحادث الأكيد Ω ، فعندئذ يمكننا أن نكتب الآتي:

$$\begin{aligned} P(\Omega) &= P \left(\sum_{i \in I} Z_i \right) = \sum_{i \in I} P(Z_i) = \sum_{i \in I} \sum_{\omega \in \Omega} P(\{\omega\}) \delta_{\omega}(Z_i) = \sum_{\omega \in \Omega} P(\{\omega\}) \sum_{i \in I} \delta_{\omega}(Z_i) \\ &= \sum_{\omega \in \Omega} P(\{\omega\}) \delta_{\omega} \left(\sum_{i \in I} Z_i \right) = \sum_{\omega \in \Omega} P(\{\omega\}) \delta_{\omega}(\Omega) = \sum_{\omega \in \Omega} P(\{\omega\}) \end{aligned}$$

وبما أنَّ $P(\Omega) = 1$ فإنه ينتج صحة دوانا.

فيما يلي سنقدم بعض الأمثلة البسيطة على كيفية تعيين الفضاء الاحتمالي وفقاً للمسلّمات الثلاث الخاصة بالفضاء الاحتمالي.

(٤, ١, ٤, ٥) أمثلة

١- لنأخذ تجربة إلقاء قطعة نقود متوازنة لثلاث مرّات متتالية، ولنقم بتعيين الفضاء الاحتمالي $[\Omega, \mathcal{A}, P]$ لهذه التجربة العشوائية، ومن ثمّ حساب احتمال الحصول على صورتين على الأقل من هذه التجربة.

الحل: لتعيين الفضاء الاحتمالي $[\Omega, \mathcal{A}, P]$ لهذه التجربة العشوائية علينا تعيين كل مركبة من مركباته، حيث لدينا:

أ- مجموعة نتائج هذه التجربة العشوائية هي:

$$\Omega = \left\{ \underbrace{HHH}_{\omega_1}, \underbrace{HHT}_{\omega_2}, \underbrace{HTH}_{\omega_3}, \underbrace{THH}_{\omega_4}, \underbrace{TTH}_{\omega_5}, \underbrace{THT}_{\omega_6}, \underbrace{TTH}_{\omega_7}, \underbrace{TTT}_{\omega_8} \right\}$$

ب- بما أنَّ Ω منتهية فإنه يمكننا أخذ الـ σ - جبر $\mathcal{A} = 2^{\Omega}$ ، وهو أقوى جبر على Ω .

ج- بما أنَّ قطعة النقود متوازنة فإنه سيكون لجميع النتائج النصيب نفسه في الظهور، ومن ثمّ يصبح لدينا:

$$Q(\{\omega_i\}) = p_i = \frac{1}{8} \quad ; \forall i = \mathbb{N}_8$$

ومن ثمّ يمكننا أن نعرّف احتمال أي حادث $A \in \mathcal{A}$ من خلال العلاقة الآتية:

$$P(A) = \sum_{i: \omega_i \in A} Q(\{\omega_i\})$$

الآن بفرض أن A هو حادث الحصول على صورتين على الأقل، فإنه سيكون احتمال A يساوي:

$$P(A) = \sum_{i=1; \omega_i \in A}^8 Q(\{\omega_i\}) = Q(\{\omega_1\}) + Q(\{\omega_2\}) + Q(\{\omega_3\}) + Q(\{\omega_4\}) = \frac{4}{8} = \frac{1}{2}$$

وأما إذا استخدمنا المبرهنة السابقة (٣، ٤، ١، ٤) فإنه سيكون لدينا:

$$\begin{aligned} P(A) &= \sum_{\omega \in \Omega} P(\{\omega\}) \delta_{\omega}(A) = P(\{\omega_1\}) \cdot 1 + P(\{\omega_2\}) \cdot 1 + P(\{\omega_3\}) \cdot 1 + P(\{\omega_4\}) \cdot 1 + P(\{\omega_5\}) \cdot 0 \\ &\quad + P(\{\omega_6\}) \cdot 0 + P(\{\omega_7\}) \cdot 0 + P(\{\omega_8\}) \cdot 0 \\ &= \frac{1}{8} + \frac{1}{8} + \frac{1}{8} + \frac{1}{8} = \frac{4}{8} = \frac{1}{2} \end{aligned}$$

علماً أنه لدينا $P(\{\omega\}) = \frac{1}{8}$ من أجل كل $\omega \in \Omega$.

٢- لنأخذ تجربة إلقاء حجر نرد متوازن لمرة واحدة فقط، ولنقم بتعيين الفضاء الاحتمالي $[\Omega, \mathcal{A}, P]$ لهذه التجربة العشوائية، ومن ثم حساب احتمال الحصول على عدد فردي من هذه التجربة.

الحل: من أجل تعيين الفضاء الاحتمالي $[\Omega, \mathcal{A}, P]$ لهذه التجربة العشوائية نجد ما يلي:

أ- مجموعة نتائج تجربة إلقاء حجر نرد لمرة واحدة هي $\Omega = \{1, 2, 3, 4, 5, 6\}$.

ب- بما أن Ω منتهية فإنه يمكننا أخذ الـ σ -جبر فوق Ω هو $\mathcal{A} = 2^\Omega$.

ج- بسبب أن Ω منتهية فإنه يمكننا أن نعرف احتمال أي حادث $A \in \mathcal{A}$ من خلال العلاقة الآتية:

$$P(A) = \sum_{i: \omega_i \in A} Q(\{\omega_i\})$$

وبما أن حجر النرد متوازن فإنه سيكون لدينا:

$$Q(\{\omega_i\}) = p_i = \frac{1}{6} \quad ; i = 1, 2, 3, 4, 5, 6$$

والآن بفرض أن A هو حادث الحصول على عدد فردي، فإنه سيكون لدينا احتمال الحصول على عدد فردي من هذه التجربة يساوي:

$$P(A) = \sum_{i=1; \omega_i \in A}^6 Q(\{\omega_i\}) = Q(\{\omega_1\}) + Q(\{\omega_3\}) + Q(\{\omega_5\}) = \frac{3}{6} = \frac{1}{2}$$

وأما باستخدام المبرهنة السابقة (٣، ٤، ١، ٤) فإننا نجد:

$$\begin{aligned} P(A) &= \sum_{\omega \in \Omega} P(\{\omega\}) \delta_{\omega}(A) \\ &= P(\{\omega_1\}) \cdot 1 + P(\{\omega_2\}) \cdot 0 + P(\{\omega_3\}) \cdot 1 + P(\{\omega_4\}) \cdot 0 + P(\{\omega_5\}) \cdot 1 + P(\{\omega_6\}) \cdot 0 \\ &= \frac{1}{6} + \frac{1}{6} + \frac{1}{6} = \frac{3}{6} = \frac{1}{2} \end{aligned}$$

علماً أنه لدينا في هذا المثال $P(\{\omega\}) = \frac{1}{8}$ من أجل كل $\omega \in \Omega$.

(٤, ٢) الاحتمالات الشرطية

Conditional Probability

لقد قمنا فيما سبق بالتعرف على بنية الفضاء الاحتمالي لتجربة عشوائية ما، وحساب احتمالات لحوادث تتعلق بتجربة عشوائية مفروضة، إلا أنه يصادفنا في كثير من الحالات حساب احتمالات لحوادث ذات طبيعة شرطية، فعلى سبيل المثال لو أمعنا النظر في الأسئلة الآتية:

أ - ما هو احتمال هطول الأمطار علماً أن السماء ملبدة بالغيوم؟

ب - ما هو احتمال وقوع حادث سير على طريق معين علماً أنه طريق زلق؟

ج - في مصنع لإنتاج سلعة معينة يوجد خطوط للإنتاج L_1, L_2, \dots, L_k قمنا بسحب قطعة من الإنتاج الكلي للمصنع فوجدناها تالفة، فما هو احتمال أن تكون هذه القطعة من إنتاج الخط L_2 ؟

نلاحظ هنا أن المطلوب حساب احتمال حادث معين إذا علم تحقق وقوع حادث آخر سابق له، ولتوضيح ذلك أكثر لنأخذ على سبيل المثال تجربة إلقاء حجر نرد متوازن لمرة واحدة فقط، ولنطرح السؤال الآتي:

ما هو احتمال الحصول على الرقم 3 علماً أننا قد حصلنا على عدد فردي؟

للإجابة على هذا السؤال لنرمز بـ A لحادث الحصول على العدد 3 وكذلك بـ B لحادث الحصول على عدد فردي، فيكون لدينا:

$$A = \{3\} \quad \& \quad B = \{1, 3, 5\}$$

ولكن بعد علمنا بالحصول على عدد فردي فإن الحالات الممكنة للتجربة ستصبح 1، 3 و 5، ومن ثم اختزل فضاء نتائج التجربة Ω إلى الحادث B ، ومنه بحسب مبدأ لابلاس في الاحتمالات سيكون الاحتمال المطلوب يساوي النسبة الآتية:

$$\frac{\text{عدد الحالات الملائمة للحادث } A}{\text{عدد الحالات الممكنة للتجربة}} = \frac{|A \cap B|}{|B|}$$

فلو قمنا الآن بتقسيم البسط والمقام على $|\Omega|$ فإنه يصبح لدينا:

$$\frac{\frac{1}{6}}{\frac{3}{6}} = \frac{\frac{|A \cap B|}{|\Omega|}}{\frac{|B|}{|\Omega|}} = \frac{P(A \cap B)}{P(B)}$$

إذن احتمال الحصول على العدد 3 علماً أننا حصلنا على عدد فردي يساوي قيمة النسبة $\frac{P(A \cap B)}{P(B)}$ ويساوي $\frac{1}{3}$ ، وهنا يشترط أن يكون $0 < P(B)$ وذلك لأنه لا معنى للنسبة السابقة عندما يكون $P(B) = 0$.

الآن وبعد هذا التقديم يمكننا أن نصيغ تعريف الاحتمال الشرطي على النحو الآتي.

(٤, ٢, ١) تعريف (الاحتمال الشرطي لحادث (Conditional Probability of an Event

ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتمالياً معطى، وليكن A و B حادثين من \mathcal{A} بحيث $0 < P(B)$. عندئذ تدعى قيمة النسبة العددية

بـ **الاحتمال الشرطي** للحادث A علماً أن الحادث B تحقق وقوعه مسبقاً، ويرمز له اصطلاحاً بالرمز $P(A|B)$ ، أي إن:

$$P(A|B) := \frac{P(A \cap B)}{P(B)}$$

[4,12]

(١, ١, ٢, ٤) ملاحظات

- ١- فيما يلي وعلى سبيل التبسيط والاختصار سنقرأ $P(A|B)$ على النحو الآتي: **الاحتمال الشرطي لـ A بالنسبة إلى B** .
- ٢- في الحالة الخاصة عندما تكون Ω منتهية ولجميع نتائجها النصيب نفسه في الظهور، فإنه يمكننا حساب الاحتمال الشرطي من خلال العلاقة الآتية:

$$P(A|B) = \frac{|A \cap B|}{|B|} \quad ; |B| > 0 \quad [4,13]$$

- ٣- من أجل B حادث مُثبت من \mathcal{A} مع $0 < P(B)$ تكون خواص الاحتمال الشرطي $P(\cdot|B)$ على الفضاء المقيس $[\Omega \cap B, \mathcal{A} \cap B]$ هي خواص الدالة الاحتمالية $P(\cdot)$ نفسها على الفضاء المقيس $[\Omega, \mathcal{A}]$ ، علماً أن:

$$\mathcal{A} \cap B = \{A \cap B ; \forall A \in \mathcal{A}\}$$

ولذلك يُرمز (في بعض الأحيان) للاحتمال الشرطي $P(\cdot|B)$ بالرمز $P_B(\cdot)$ للدلالة على أن P_B هنا له خصائص القياس الاحتمالي.

- ٤- عندما يكتب $P(AB)$ إنما يقصد بذلك $P(A \cap B)$ ، ولذلك سوف نقوم بحذف رمز التقاطع \cap بين الحوادث على سبيل التبسيط ونذكره عند الضرورة أو على سبيل التذكير به أحياناً.

- ٥- من مبدأ التناظر في استخدام الرموز يمكننا في حال $0 < P(A)$ أن نكتب من أجل $B \in \mathcal{A}$ الآتي:

$$P(B|A) := \frac{P(A \cap B)}{P(A)} \quad [4,14]$$

(٢, ١, ٢, ٤) نتائج

- ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتمالي مفروضاً، وليكن A حادثاً من \mathcal{A} مع $0 < P(A)$ ، فعندئذ يمكن للقارئ التحقق من صحة النتائج الآتية:

$$1- \text{ لدينا } P(\emptyset|A) = 0 \text{ محققةً دوماً.}$$

- ٢- من أجل B حادث من \mathcal{A} مع $B \supseteq A$ فإنه سيكون $P(B|A) = 1$ ، ومن ثم ينتج لدينا $P(\Omega|A) = 1$.

- ٣- من أجل أي حادثين متنافيين B و C من \mathcal{A} يكون لدينا:

$$P(B+C|A) = P(B|A) + P(C|A) \quad [4,15]$$

- ٤- من أجل أي حادثين B و C من \mathcal{A} يكون لدينا:

$$P(BC|A) = P(B|AC) \cdot P(C|A) \quad [4,16]$$

- ٥- من النتيجة ٢ و ٣ السابقتين ينتج لدينا أن:

$$P(\bar{B}|A) = 1 - P(B|A) \quad [4,17]$$

- ٦- إذا كان A و B حادثين كفيين من \mathcal{A} مع $0 < P(A)$ و $0 < P(B)$ ، فعندئذ نجد من تعريف الاحتمال الشرطي أن:

$$P(AB) = P(A) \cdot P(B|A) = P(B) \cdot P(A|B) \quad [4,18]$$

وهذه العلاقة الأخيرة تُدعى **قانون الضرب في الاحتمالات** التي يمكن تعميمها كما في المبرهنة الآتية.

(٤, ٢, ٢) مبرهنة (قانون الضرب في الاحتمالات (Multiplication Law of Probability)

ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتماليًا معطى، ولتكن A_1, A_2, \dots, A_n حوادث من \mathcal{A} ، فإذا كان:

$$P(A_1 A_2 \dots A_{n-1}) > 0 \quad (*)$$

فعندئذ تكون العلاقة الآتية مُحَقَّقة:

$$P(A_1 A_2 \dots A_n) = P(A_1) \cdot P(A_2 | A_1) \cdot P(A_3 | A_1 A_2) \cdot \dots \cdot P(A_{n-1} | A_1 A_2 \dots A_{n-2}) \cdot P(A_n | A_1 A_2 \dots A_{n-1}) \quad [4,19]$$

البرهان: لإثبات صحة هذه العلاقة يمكننا بادئ ذي بدء وبسهولة إثبات أنه إذا كانت العلاقة (*) مُحَقَّقة فإنه سيكون لدينا:

$$P(A_1 A_2 \dots A_k) > 0 \quad ; \forall k \in \mathbb{N}_{n-1}$$

وستثبت صحة العلاقة [4,19] بطريقة الاستقراء الرياضي، حيث نجد من تعريف الاحتمال الشرطي أنه من أجل $n = 2$ لدينا:

$$P(A_1 A_2) = P(A_1) \cdot P(A_2 | A_1)$$

وهذا يعني أن العلاقة [4,19] صحيحة من أجل $n = 2$.

الآن سنفترض أن العلاقة [4,19] صحيحة من أجل $n - 1$ ولتثبت صحتها من أجل قيمة ما $n \in \mathbb{N}$ ، ومن أجل ذلك سنضع $B = A_1 A_2 \dots A_{n-1}$ ، فعندئذ يكون لدينا الآتي:

$$\begin{aligned} P(A_1 A_2 \dots A_n) &= P(B A_n) = P(B) \cdot P(A_n | B) \\ &= P(A_1 A_2 \dots A_{n-1}) \cdot P(A_n | A_1 A_2 \dots A_{n-1}) \\ &= P(A_1) \cdot P(A_2 | A_1) \cdot P(A_3 | A_1 A_2) \cdot \dots \cdot P(A_{n-1} | A_1 A_2 \dots A_{n-2}) \cdot P(A_n | A_1 A_2 \dots A_{n-1}) \end{aligned}$$

وهذا يعني أن العلاقة [4,19] صحيحة من أجل أية قيمة $n \in \mathbb{N}$ ، وبذلك يتم البرهان.


المبرهنة الآتية تمكننا من حساب احتمال حادث ما متعلق بالتجربة العشوائية إذا كان لدينا تجزئة للحدث الأكيد.

(٤, ٢, ٣) مبرهنة (صيغة الاحتمال التام (Total Probability Formula)

ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتماليًا معطى، و $\mathcal{Z} = \{Z_i ; i \in I \subseteq \mathbb{N}\}$ تجزئة للحدث الأكيد Ω ذراتها من \mathcal{A} وتحقق العلاقة $0 < P(Z_i)$ من أجل كل $i \in I$ ، فعندئذ من أجل أي حادث A من \mathcal{A} تكون العلاقة الآتية مُحَقَّقة:

$$P(A) = \sum_{i \in I} P(Z_i) \cdot P(A | Z_i) \quad [4,20]$$

وهذه العلاقة الأخيرة تُعرف باسم **صيغة الاحتمال التام**.



الشكل (٤, ٣)

البرهان: بما أن ذرات التجزئة هي حوادث متنافية متنى متنى فإنه يمكننا أن نكتب

ما يلي:

$$A = A \cap \Omega = A \cap \left(\sum_{i \in I} Z_i \right) = \sum_{i \in I} A Z_i$$

وبما أن $0 < P(Z_i)$ من أجل كل $i \in I$ ، فإنه باستخدام خواص القياس الاحتمالي P وقانون الضرب في الاحتمالات نحصل على العلاقة الآتية التي تثبت صحة دعوانا:

$$P(A) = P(A \cap \Omega) = P\left(\sum_{i \in I} A Z_i\right) = \sum_{i \in I} P(A Z_i) = \sum_{i \in I} P(Z_i) \cdot P(A | Z_i)$$

الآن، بفرض أن $\mathcal{Z} = \{Z_i ; i \in I \subseteq \mathbb{N}\}$ تجزئة للحدث الأكيد Ω ذراتها من \mathcal{A} ، فإنه قد يصادفنا في بعض الحالات حساب الاحتمال الشرطي لذرة Z_k بالنسبة إلى حدث $A \in \mathcal{A}$. إن المبرهنة الآتية تُعطينا العلاقة التي تستخدم لحساب مثل هذا الاحتمال الشرطي، وتعرف هذه العلاقة باسم **نظرية بيز (أو قانون بيز أو دستور بيز (Bayes' law or Bayes' rule))** في الاحتمالات، وهي تنسب إلى الإحصائي والفيلسوف الإنكليزي **بيز (Thomas Bayes (1701–1761))**.

(٤, ٢, ٤) مبرهنة (نظرية بيز (Bayes's theorem))

ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتمالي معطى، و $\mathcal{Z} = \{Z_i ; i \in I \subseteq \mathbb{N}\}$ تجزئة للحدث الأكيد Ω ذراتها من \mathcal{A} وتحقق العلاقة $0 < P(Z_i) \text{ من أجل كل } i \in I$ ، فعندئذ من أجل قيمة $k \in I$ يكون ما يلي محققاً:

$$P(Z_k | A) = \frac{P(Z_k) \cdot P(A | Z_k)}{\sum_{i \in I} P(Z_i) \cdot P(A | Z_i)} \quad [4,21]$$

البرهان: من تعريف الاحتمال الشرطي، ومن صيغة الاحتمال التام يمكننا أن نكتب الآتي من أجل كل $k \in I$:

$$P(Z_k | A) = \frac{P(AZ_k)}{P(A)} = \frac{P(Z_k) \cdot P(A | Z_k)}{P(A)} = \frac{P(Z_k) \cdot P(A | Z_k)}{\sum_{i \in I} P(Z_i) \cdot P(A | Z_i)}$$

وبهذا يتم البرهان.

(٤, ٢, ٤, ١) ملاحظات

١- إن العلاقة السابقة [4,21] تُعرف باسم **صيغة بيز في الاحتمالات**، وتمكننا من حساب الاحتمال الشرطي لذرة من تجزئة للحدث الأكيد إذا تحقق وقوع حدث ما متعلق بالتجربة العشوائية مسبقاً.

٢- لقد نظر **بيز** إلى احتمال حدث ما على أنه درجة اعتقاد بحدوثه أو عدم حدوثه، وهذا التعريف يسمح له أن يدرس قضايا احتمالية لا ينطبق عليها مفهوم التكرار النسبي لأنه لا يُكرر التجربة عدداً لا منتهياً من المرات، خاصة وأنه يوجد الكثير من التجارب التي لا يمكن تكرارها، مثل احتمال الموت لكائن حي، أو الوصول إلى مجرة ما بعيدة، أو...، ولذلك بدأ **بيز** باستخدام درجة الاعتقاد حول فرضية ما حيث سمى الحوادث Z_1, Z_2, \dots بالفرضيات المتعلقة بالمسألة المطروحة، وأما درجة الاعتقاد هذه والمقابلة لاحتمال $P(Z_i)$ فأسماها **الاحتمال الأسبق للفرضية** Z_i Prior Probability، وبعد ذلك يقوم بجمع معلومات أخرى يستخدمها ليحسن من درجة اعتقاده الذي يؤدي بدوره إلى الاحتمال $P(A | Z_i)$ والذي أسماه **الاحتمال اللاحق** a -Superior Probability Z_i .

من الاعتراضات على هذا الطرح لاحتمال هو أنه وفقاً لهذا المفهوم يُعد كثير من الناس ليس لهم درجة اعتقاد حول موضوعات كثيرة، ولكن أشار **بيز** في هذا الصدد إلى أنه في المواقف العملية وخاصة المالية منها يكون للناس درجة اعتقاد حول بعض الفرضيات مثل الربح والخسارة والأسعار، حيث يُعد ذلك كافياً كحد أدنى لاعتماد هذه الاستراتيجية في الحساب.

(٤, ٢, ٤, ٢) أمثلة

١- في مصنع لإنتاج المصابيح الكهربائية يوجد ثلاثة خطوط للإنتاج L_1, L_2 و L_3 بحيث تنتج هذه الخطوط 50%، 30% و 20% على الترتيب من نسبة الإنتاج الكلي للمصنع، ونسبة المعطّل في إنتاج هذه الخطوط على الترتيب هو 0.03، 0.02 و 0.01. الآن نقوم بسحب عشوائي لمصباح من الإنتاج الكلي للمصنع، ولنقم بحساب:

أ - احتمال أن يكون المصباح المسحوب سليماً؟

ب - احتمال أن يكون المصباح المسحوب من إنتاج الخط الأول إذا علمنا أنه وجد معطّلاً؟

الحل: للإجابة على هذه الأسئلة سنفترض أن Z_1 ، Z_2 و Z_3 هو حادث سحب مصباح من إنتاج الخط L_1 ، L_2 و L_3 على الترتيب، فنجد أن هذه الحوادث تشكل تجزئة للحادث الأكيد (الذي يمثل كل نتائج السحب من الإنتاج الكلي للمصنع)، ومن ثم بفرض A هو حادث سحب مصباح معطل من الإنتاج الكلي فعندئذ من أجل الطلب:

أ) سنفترض أن B حادث سحب مصباح سليم من الإنتاج الكلي، فيكون لدينا $P(B) = 1 - P(A)$ ، ولكن من صيغة الاحتمال التام لدينا:

$$P(A) = \sum_{i=1}^3 P(Z_i) \cdot P(A | Z_i) = \frac{50}{100} \cdot \frac{3}{100} + \frac{30}{100} \cdot \frac{2}{100} + \frac{20}{100} \cdot \frac{1}{100} = 0.023$$

ومن ثم يكون لدينا:

$$P(B) = 1 - P(A) = 0.977$$

ب) لدينا الاحتمال المطلوب $P(Z_1 | A)$ ، وباستخدام صيغة بييز نجد:

$$P(Z_1 | A) = \frac{P(Z_1)P(A | Z_1)}{\sum_{i=1}^3 P(Z_i) \cdot P(A | Z_i)} = \frac{(0.50)(0.03)}{0.023} = 0.6522$$

وبهذا ينتهي حل المثال.

٢- لدينا ثلاثة صناديق بحيث يحوي الصندوق الأول أربع كرات حمراء وثلاث كرات سوداء بينما يحوي الثاني ثلاث كرات حمراء وخمس كرات بيضاء، وأخيراً يحوي الصندوق الثالث ثلاث كرات سوداء وثلاث كرات بيضاء. الآن بفرض أن لكل صندوق النصيب نفسه في السحب وأن جميع الكرات متماثلة تماماً (ومن ثم لها النصيب نفسه في الاختيار)، وأتينا قمنا بسحب عشوائي لصندوق من هذه الصناديق، ومن ثم سحب كرة من هذا الصندوق، فعندئذ:

أ- ما هو احتمال أن تكون الكرة المسحوبة بيضاء؟

ب- إذا علمنا أن الكرة المسحوبة كانت بيضاء، فما هو احتمال أن تكون هذه الكرة قد سُحبت من الصندوق الثاني؟

الحل: للإجابة على هذه الأسئلة سنفترض أن Z_1 ، Z_2 و Z_3 هو حادث سحب كرة من الصندوق الأول والثاني والثالث على الترتيب، فنجد أن Z_1 ، Z_2 و Z_3 تُشكل تجزئة للحادث الأكيد Ω (الذي يمثل مجموعة كل السحوبات الممكنة للكرات)، وكذلك سنفترض أن W هو حادث سحب كرة بيضاء من الصندوق، فعندئذ من أجل الطلب:

أ- يكون الاحتمال المطلوب هو $P(W)$ ، وبما أنه لدينا تجزئة للحادث الأكيد، فإنه باستخدام صيغة الاحتمال التام نجد ما يلي:

$$P(W) = \sum_{i=1}^3 P(Z_i) \cdot P(W | Z_i) = \frac{1}{3} \cdot \frac{0}{7} + \frac{1}{3} \cdot \frac{5}{8} + \frac{1}{3} \cdot \frac{3}{6} = 0.375$$

ب- يكون الاحتمال المطلوب هو $P(Z_2 | W)$ ، وبما أن لدينا تجزئة للحادث الأكيد، فإنه باستخدام صيغة بييز يكون لدينا:

$$P(Z_2 | W) = \frac{P(Z_2) \cdot P(W | Z_2)}{\sum_{k=1}^3 P(Z_k) \cdot P(W | Z_k)} = \frac{\frac{1}{3} \cdot \frac{5}{8}}{0.375} = 0.555$$

وبهذا ينتهي حل المثال.

٣- لنأخذ تجربة إلقاء قطعة نقود متوازنة لثلاث مرات متتالية، ولنقم بحساب احتمال الحصول على صورة في الرمية الأخيرة علماً أننا حصلنا على صورة واحدة على الأقل خلال هذه الرميات الثلاث.

الحل: من أجل ذلك لنفترض أن A هو الحادث الذي يعبر عن حصولنا على صورة في الرمية الأخيرة و B هو الحادث الذي يعبر عن حصولنا على صورة واحدة على الأقل خلال هذه الرميات الثلاث، فعندئذ يكون لدينا:

$$A = \{HHH, HTH, THH, TTH\}$$

$$B = \{HHH, HHT, HTH, THH, TTH, THT, HTT\}$$

ومن معطيات المسألة لدينا قطعة النقود متوازنة، ومنه يكون الاحتمال الشرطي ل A بالنسبة إلى B يساوي:

$$P(A|B) = \frac{P(AB)}{P(B)} = \frac{4/8}{7/8} = \frac{4}{7}$$

وبهذا ينتهي حل المثال.

٤- لدينا وعاء يحوي m كرة متماثلة منها n كرة حمراء والباقي $m-n$ كرة لونها أسود، علماً أن $m > n$. قمنا بسحب كرتين على التوالي دون إعادتهما إلى الصندوق، فإذا علمت أن الكرة المسحوبة في المرة الأولى كانت حمراء، فما هو احتمال أن تكون الكرة المسحوبة أخيراً سوداء؟

الحل: للإجابة على هذا السؤال سنرمز ب A لحادث سحب كرة حمراء في المرة الأولى وب B لحادث سحب كرة سوداء في المرة الثانية، فعندئذ يكون $P(A) = \frac{n}{m} > 0$ ، ومن ثم الاحتمال المطلوب يساوي:

$$P(B|A) = \frac{P(AB)}{P(A)} = \frac{(m-n)/(m-1)}{n/m} = \frac{m(m-n)}{n(m-1)}$$

وبهذا ينتهي حل المثال.

(٤,٣) استقلال الحوادث

Independence of Events

إن مفهوم الاستقلال بين الحوادث يُنظر إليه كأحد المفاهيم المهمة جداً في الاحتمالات، ولذلك سنقدم فيما يلي دراسة لهذا الموضوع، وفي فصل قادم سنبحث في استقلال المتغيرات العشوائية، علماً أن استقلال المتغيرات العشوائية يرد إلى مفهوم الاستقلال بين الحوادث أيضاً.

ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتمالي، و A و B حادثين من \mathcal{A} ، فعندئذ يقال إن الحادث A مستقل Independent عن الحادث B إذا كان تحقق وقوع الحادث B لا يؤثر في تحقق وقوع الحادث A ولا بأي شكل من الأشكال، وهذا يعني أنه بفرض $0 < P(B)$ فإن $P(A|B) = P(A)$ ، ومن ثم باستخدام تعريف الاحتمال الشرطي ينتج ما يلي:

$$P(AB) = P(B) \cdot P(A|B) = P(A) \cdot P(B)$$

ومنه ينتج لدينا أنه إذا كان الحادث A مستقل عن الحادث B فإن العلاقة الآتية ستكون محققة:

$$P(AB) = P(A) \cdot P(B)$$

وبشكل مماثل يكون B مستقل عن A بحسب المفهوم السابق إذا تحققت العلاقة السابقة أيضاً، ونقول حينئذ إن الحادثين A و B مستقلان بعضهما عن بعض، وهكذا يمكننا أن نصيغ تعريف استقلال حادثين على النحو الآتي.

(٤,٣,١) تعريف (استقلال حادثين)

ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتمالي، و A و B حادثين من \mathcal{A} ، فعندئذ يقال إن الحادث A مستقل عن الحادث B إذا تحققت من أجلهما العلاقة الآتية:

$$P(A \cap B) = P(A) \cdot P(B) \quad [4,22]$$

ونلاحظ هنا أنَّ العلاقة الأخيرة [4,22] تبقى سارية المفعول حتى لو كان $P(A) = 0$ أو $P(B) = 0$.

الآن، وبشكل مماثل لما سبق، يمكننا صياغة الاستقلال بين ثلاثة حوادث A_1, A_2 و A_3 من \mathcal{A} حيث يُقال عن هذه الحوادث إنها مستقلة إذا من أجلها ما يلي مُحققاً:

١- من أجل كل $i, j \in \mathbb{N}_3$ مع $i \neq j$ لدينا:

$$P(A_i \cap A_j) = P(A_i) \cdot P(A_j)$$

٢- لدينا:

$$P(A_1 \cap A_2 \cap A_3) = P(A_1) \cdot P(A_2) \cdot P(A_3)$$

على العموم يوجد تعريف أكثر عمومية لاستقلال الحوادث حيث يُقدّم صياغة لاستقلال عدد منته من الحوادث، وهذا هو محتوى التعريف الآتي.

(٢, ٣, ٤) تعريف (الاستقلال لعدد منته من الحوادث Independence of Finite Number of Events)

ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتمالياً معطى، ولنأخذ A_1, A_2, \dots, A_n من \mathcal{A} ، فعندئذ يُقال عن هذه الحوادث إنها مستقلة عشوائياً Stochastic Independent (أو مستقلة إحصائياً Statistical Independent) إذا كان من أجل أي $k \in \mathbb{N}_n$ مع $1 < k$ ، وكل $i_j \in \mathbb{N}$ مع $j \in \mathbb{N}_n$ وبحيث يكون $1 \leq i_1 < i_2 < \dots < i_k \leq n$ ، فإنَّ العلاقة الآتية مُحققة:

$$P(A_{i_1} \cap A_{i_2} \cap \dots \cap A_{i_k}) = P(A_{i_1}) \cdot P(A_{i_2}) \cdot \dots \cdot P(A_{i_k}) \quad [4,23]$$

(١, ٢, ٣, ٤) ملاحظات

١- من التعريف السابق للاستقلال العشوائي يتضح لنا أنه إذا كانت A_1, A_2, \dots, A_n من \mathcal{A} حوادث مستقلة عشوائياً فإنَّ أية أسرة جزئية منها ستكون مستقلة عشوائياً أيضاً.

٢- في الحالة الخاصة عندما يكون من أجل كل $i, j \in \mathbb{N}_n$ مع $i \neq j$ لدينا:

$$P(A_i \cap A_j) = P(A_i) \cdot P(A_j) \quad [4,24]$$

فعندئذ يُقال عن الحوادث A_1, A_2, \dots, A_n إنها مستقلة مثنى مثنى Pairwise Independent، ويُلاحظ هنا أنه إذا كانت هذه الحوادث مستقلة مثنى مثنى فليس بالضرورة أن تكون هذه الحوادث مستقلة عشوائياً.

٣- إذا كان من أجل حادث A من \mathcal{A} لدينا $P^2(A) = P(A)$ ، فعندئذ يُقال عن الحادث A إنه مستقل عن نفسه.

(٢, ٣, ٤) نتائج

يمكن للقارئ التَّحقُّق من صحة النتيجة الآتيتين:

١- إنَّ كلاً من الحادثين \emptyset و Ω مستقل عن نفسه.

٢- إنَّ الحادث Ω مستقل عن أي حادث آخر A من \mathcal{A} .

(٣, ٢, ٣, ٤) أمثلة

١- لنأخذ تجربة إلقاء قطعة نقود متوازنة لثلاث مرات متتالية، وليكن A, B و C هي حوادث الحصول على صورة في الرمية الأولى، والثانية، والثالثة على الترتيب، فعندئذ نجد أنَّ هذه الحوادث مستقلة عشوائياً، وذلك لأنَّه لدينا:

$$P(A) = P(B) = P(C) = \frac{1}{2}$$

$$P(AB) = \frac{1}{4} = P(A) \cdot P(B) \quad \& \quad P(AC) = \frac{1}{4} = P(A) \cdot P(C)$$

$$P(BC) = \frac{1}{4} = P(B) \cdot P(C) \quad \& \quad P(ABC) = \frac{1}{8} = P(A) \cdot P(B) \cdot P(C)$$

٢- ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتماليًا معطى، وبحيث:

$$\Omega = \{\omega_1, \omega_2, \omega_3, \omega_4\} \quad \& \quad \mathcal{A} = 2^\Omega \quad \& \quad P(\{\omega_i\}) = \frac{1}{4} \quad ; \quad \forall i \in \mathbb{N}_4$$

ولنأخذ الحوادث $A_1 = \{\omega_1, \omega_2\}$ ، $A_2 = \{\omega_1, \omega_3\}$ و $A_3 = \{\omega_1, \omega_4\}$ ، فنجد أن:

$$P(A_1) = P(A_2) = P(A_3) = \frac{1}{2}$$

وكذلك من أجل كل $i, j \in \mathbb{N}_3$ مع $j \neq i$ لدينا:

$$P(A_i A_j) = P(A_i) \cdot P(A_j) = \frac{1}{4}$$

ومن ثم الحوادث A_1 و A_2 و A_3 مستقلة مثنى مثنى، ولكننا نلاحظ أنها ليست مستقلة عشوائياً وذلك لأن:

$$\frac{1}{4} = P(A_1 A_2 A_3) \neq P(A_1) \cdot P(A_2) \cdot P(A_3) = \frac{1}{8}$$

٣- لنأخذ تجربة إلقاء حجر نرد متوازن لمرتين متتاليتين فقط، ولنأخذ الحوادث الآتية:

$$A = \{(i, j) ; i \in \mathbb{N}_6 \quad \& \quad j = 1, 2, 5\}$$

$$B = \{(i, j) ; i \in \mathbb{N}_6 \quad \& \quad j = 4, 5, 6\}$$

$$C = \{(i, j) ; i, j \in \mathbb{N}_6 \text{ with } i + j = 9\}$$

فنجد أن هذه الحوادث ليست مستقلة مثنى مثنى، ومن ثم فليست مستقلة عشوائياً وذلك لأن:

$$\frac{1}{6} = P(AB) \neq P(A) \cdot P(B) = \frac{1}{2} \cdot \frac{1}{2} = \frac{1}{4}$$

علماً أنه لدينا:

$$P(ABC) = \frac{1}{36} = P(A) \cdot P(B) \cdot P(C)$$

وهكذا نلاحظ من هذا المثال أنه إذا كانت العلاقة الآتية:

$$P(A_1 A_2 \dots A_n) = P(A_1) \cdot P(A_2) \cdot \dots \cdot P(A_n)$$

مُحققة من أجل حوادث مُعطاة A_1, A_2, \dots, A_n من \mathcal{A} ، فإن ذلك لا يعني أن تكون العلاقة:

$$P(A_{i_1} A_{i_2} \dots A_{i_k}) = P(A_{i_1}) \cdot P(A_{i_2}) \cdot \dots \cdot P(A_{i_k})$$

مُحققة من أجل جميع قيم الأدلة $i_j \in \mathbb{N}$ المشار إليها في التعريف السابق.

Characteristics of Independent Events (٤, ٣, ٣) خصائص الحوادث المستقلة

فيما يلي نقدم مبرهنتين توضّحان لنا بعض الخصائص للحوادث المستقلة بعضها عن بعض.

(٤, ٣, ٣, ١) مبرهنة

ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتماليًا معطى، وليكن A و B حادثين مستقلين بعضهما عن بعض، فعندئذ:

١- يكون الحادث A مستقلاً عن \bar{B} ، وكذلك الحادث \bar{A} مستقلاً عن B أيضاً.

٢- يكون الحادثان \bar{A} و \bar{B} مستقلين عن بعضهما.

٣- بفرض أن $A \supseteq A^*$ ، فعندئذ A^* و B يكونان مستقلين عن بعضهما إذا وفقط إذا كان الحادثان $A \setminus A^*$ و B مستقلين عن بعضهما.

البرهان: من أجل الطلب:

١- سنثبت استقلال A و \bar{B} فقط وذلك لأن إثبات استقلال B و \bar{A} يتم بشكل مماثل، فنجد من كون $A \supseteq A^*$ و B مستقلين عن بعضهما

ما يلي:

$$P(A \bar{B}) = P(A \setminus AB) = P(A) - P(AB)$$

$$= P(A) - P(A) \cdot P(B) = P(A) \cdot [1 - P(B)] = P(A) \cdot P(\bar{B})$$

وهذا يعني أن A و \bar{B} مستقلان عن بعضهما.

٢- من الفرض وخواص المتممات والعلاقة (٩, ٤) يمكننا أن نكتب ما يلي:

$$P(AB) = P(\overline{A \cup B}) = 1 - P(A \cup B) = 1 - [P(A) + P(B) - P(AB)]$$

$$= 1 - [P(A) + P(B) - P(A) \cdot P(B)]$$

$$= [1 - P(A)] \cdot [1 - P(B)] = P(\bar{A}) \cdot P(\bar{B})$$

وهذا يعني أن \bar{A} و \bar{B} مستقل كل منهما عن الآخر.

٣- أ- من أجل لزوم الشرط:

لدينا الحادثان A^* و B مستقلان بعضهما عن بعض، فعندئذ يكون:

$$P(B) \cdot P(A^*) = P(A^* B) = P(AB \setminus [(A \setminus A^*) \cap B])$$

$$= P(AB) - P((A \setminus A^*) \cap B) = P(A) \cdot P(B) - P((A \setminus A^*) \cap B)$$

ومن ثم يتج لدينا:

$$P((A \setminus A^*) \cap B) = P(B) \cdot [P(A) - P(A^*)] = P(B) \cdot P(A \setminus A^*)$$

وهذا يعني أن $A \setminus A^*$ و B مستقل كل منهما عن الآخر.

ب) من أجل كفاية الشرط:

لدينا الحادثان $A \setminus A^*$ و B مستقلان بعضهما عن بعض، ولنثبت استقلال A^* عن B وذلك على النحو الآتي:

باستخدام خواص الدالة الاحتمالية P ، ومن استقلال الحادثين A و B يمكننا أن نكتب الآتي:

$$P(B) \cdot P(A \setminus A^*) = P((A \setminus A^*) \cap B) = P(AB \setminus A^* B)$$

$$= P(AB) - P(A^* B) = P(A) \cdot P(B) - P(A^* B)$$

التي نجد منها أن:

$$P(A^*B) = P(B) \cdot [P(A) - P(A \setminus A^*)] = P(B) \cdot P(A^*)$$

وهذا يعني أن A^* و B مستقل كل منهما عن الآخر.

(٢, ٣, ٣, ٤) مبرهنة

ليكن $[\Omega, \mathcal{A}, P]$ فضاءً احتماليًا معطى، ولتكن $(A_n)_{n \in \mathbb{N}}$ متتالية حوادث متنافية متنى متنى من \mathcal{A} ، فعندئذ إذا كان من أجل حادث B من \mathcal{A} لدينا الحوادث A_n و B مستقلة من أجل أية قيمة $n \in \mathbb{N}$ فإنه سيكون B مستقل عن $\bigcup_{n=1}^{\infty} A_n$ أيضاً.

البرهان: من أجل أي $n \in \mathbb{N}$ لدينا الحادث A_n مستقل عن B ، ومن ثم باستخدام خواص الدالة الاحتمالية P والفرض المقدم يكون لدينا ما يلي:

$$\begin{aligned} P\left(B \cap \bigcup_{n=1}^{\infty} A_n\right) &= P\left(\sum_{n=1}^{\infty} (B A_n)\right) = \sum_{n=1}^{\infty} P(B A_n) = \sum_{n=1}^{\infty} P(B) \cdot P(A_n) \\ &= P(B) \sum_{n=1}^{\infty} P(A_n) = P(B) \cdot P\left(\bigcup_{n=1}^{\infty} A_n\right) \end{aligned}$$

وهذا يعني أن $\bigcup_{n=1}^{\infty} A_n$ و B مستقل كل منهما عن الآخر.

(٣, ٣, ٣, ٤) ملاحظة

إن المبرهنة السابقة غير قابلة للعكس بمعنى أنه إذا كان B مستقل عن $\bigcup_{n=1}^{\infty} A_n$ فليس بالضرورة أن تكون الحوادث A_n و B مستقلة من أجل أية قيمة $n \in \mathbb{N}$ ، فلو أخذنا على سبيل المثال $[\Omega, \mathcal{A}, P]$ فضاءً احتماليًا معطى على النحو الآتي:

$$\Omega = \{\omega_1, \omega_2, \omega_3\} \quad \& \quad \mathcal{A} = 2^{\Omega} \quad \& \quad P(\{\omega_i\}) = \frac{1}{3} \quad ; \quad \forall i \in \mathbb{N}_3$$

ولنأخذ الحوادث البسيطة $A_1 = \{\omega_1\}$ ، $A_2 = \{\omega_2\}$ و $A_3 = \{\omega_3\}$ ، فنجد أن هذه الحوادث متنافية متنى متنى مع $\Omega = \sum_{i=1}^3 A_i$ ، ولنأخذ متتالية الحوادث $(A_n)_{n \in \mathbb{N}}$ من \mathcal{A} مع $A_i = \emptyset$ من أجل $4 \leq i$ ، فيكون لدينا $\Omega = \sum_{n=1}^{\infty} A_n$ ، وبما أن الحادث Ω الأكيد مستقل عن أي حادث $B \in \mathcal{A}$ ، فإن ذلك يعني أن الحادث $\sum_{n=1}^{\infty} A_n$ مستقل عن B ، فلو أخذنا على سبيل المثال $B = \{\omega_1, \omega_2\}$ لوجدنا الآتي:

$$\frac{1}{3} = P(A_1 B) \neq P(A_1) \cdot P(B) = \frac{2}{9}$$

(٤, ٣, ٣, ٤) أمثلة

١- لدينا نظام اتصالات مكون من ثلاث محطات S_1 ، S_2 و S_3 تعمل كل منهما بشكل مستقل عن الأخريات، فإذا كان احتمال تعطل هذه المحطات خلال السنوات الخمس القادمة على الترتيب هو 0.01، 0.02 و 0.03، فعندئذ:

أ- ما هو احتمال عمل المحطات الثلاث خلال السنوات الخمس القادمة؟

ب- ما هو احتمال عمل المحطة S_2 وتعطل S_1 و S_3 خلال السنوات الخمس القادمة؟

ج- ما هو احتمال تعطل محطتين على الأكثر من المحطات الثلاث خلال السنوات الخمس القادمة؟

الحل: للإجابة على هذه الأسئلة سنفترض أن A_1 ، A_2 و A_3 هو حادث تعطل المحطة S_1 ، S_2 و S_3 خلال السنوات الخمس

القادمة على الترتيب، فعندئذ بحسب الفرض ستكون الحوادث A_1 ، A_2 و A_3 مستقلة عشوائياً، ومنه يكون لدينا من أجل الطلب:
 أ - بفرض أن A هو الحادث الذي يُعبر عن عمل المحطات الثلاث خلال السنوات الخمس القادمة، فإنه سيكون لدينا $\bar{A}_1 \bar{A}_2 \bar{A}_3 = A$ ، ومن ثم بسبب استقلال الحوادث A_1 ، A_2 و A_3 ومن المبرهنة (١، ٣، ٣، ٤) يمكننا أن نكتب الآتي:

$$P(A) = P(\bar{A}_1 \bar{A}_2 \bar{A}_3) = P(\bar{A}_1) \cdot P(\bar{A}_2) \cdot P(\bar{A}_3) = 0.9411$$

ب - بفرض أن B هو الحادث الذي يُعبر عن عمل المحطة S_2 وتعطل S_1 و S_3 خلال السنوات الخمس القادمة هو $B = A_1 \bar{A}_2 A_3$ ، ومن ثم بسبب استقلال الحوادث A_1 ، A_2 و A_3 ومن المبرهنة (١، ٣، ٣، ٤) يكون لدينا ما يلي:

$$P(B) = P(A_1 \bar{A}_2 A_3) = P(A_1) \cdot P(\bar{A}_2) \cdot P(A_3) = 0.0003$$

ج - بفرض أن C هو الحادث الذي يعبر عن تعطل محطتين على الأكثر خلال السنوات الخمس القادمة فإنه يكون لهذا الحادث العرض الآتي:

$$C = \bar{A}_1 \bar{A}_2 \bar{A}_3 + \bar{A}_1 \bar{A}_2 A_3 + \bar{A}_1 A_2 \bar{A}_3 + A_1 \bar{A}_2 \bar{A}_3 + \bar{A}_1 A_2 A_3 + A_1 \bar{A}_2 A_3 + A_1 A_2 \bar{A}_3$$

ومن ثم بسبب استقلال الحوادث A_1 ، A_2 و A_3 ومن المبرهنة (٤-٣-٣-١) يكون لدينا ما يلي:

$$P(C) = P(\bar{A}_1) \cdot P(\bar{A}_2) \cdot P(\bar{A}_3) + P(\bar{A}_1) \cdot P(\bar{A}_2) \cdot P(A_3) + P(\bar{A}_1) \cdot P(A_2) \cdot P(\bar{A}_3) + P(A_1) \cdot P(\bar{A}_2) \cdot P(\bar{A}_3) \\ + P(\bar{A}_1) \cdot P(A_2) \cdot P(A_3) + P(A_1) \cdot P(\bar{A}_2) \cdot P(A_3) + P(A_1) \cdot P(A_2) \cdot P(\bar{A}_3) = 0.999994$$

وبذلك اكتمل الحل.

هذا ما تيسر تقديمه من أجل الجزء النظري والتطبيقي لهذا الفصل

تمارين الفصل الرابع

١- أثبت صحة العلاقات الآتية:

a) $\sum_{k=0}^n \binom{n}{k} = 2^n$

b) $\sum_{k=0}^n \binom{n}{k}^2 = \binom{2n}{n}$

c) $\sum_{k=0}^n \binom{n}{k} (-1)^k = \sum_{k=0}^n \binom{n}{k} (-1)^{n-k} = 0$

٢- ليكن $[\Omega, \mathcal{A}, P]$ فضاءً احتمالياً معطى، وبفرض أن A و B حادثين متنافيين ومستقلين من \mathcal{A} مع $P(A) = 0.35$ ، فما هو احتمال الحادث B ؟

٣- ليكن $[\Omega, \mathcal{A}, P]$ فضاءً احتمالياً معطى، ولنأخذ A و B حادثين من \mathcal{A} ومحققين للعلاقات الآتية:

$$P(A) = 0.45, \quad P(A \setminus B) = 0.25 \quad \& \quad P(B \setminus A) = 0.25$$

والمطلوب ما يلي:

أ- حساب الاحتمالات الآتية:

$$\begin{array}{lll} \text{a) } P(\bar{A}) & \& \text{b) } P(B) & \& \text{c) } P(A \cap B) \\ \text{d) } P(A \cup B) & \& \text{e) } P(\bar{A} \cup \bar{B}) & \& \text{f) } P(B | A) \end{array}$$

ب- تحقق إن كان الحادثان A و B مستقلين أم لا.

٤- ليكن $[\Omega, \mathcal{A}, P]$ فضاءً احتمالياً معطى، ولنأخذ A و B حادثين من \mathcal{A} ومحققين للعلاقات الآتية:

$$P(A \cup B) = 0.85, \quad P(A \setminus B) = 0.20 \quad \& \quad P(B \setminus A) = 0.35$$

والمطلوب ما يلي:

أ- حساب الاحتمالات الآتية:

$$\begin{array}{lll} \text{a) } P(A \cap B) & \& \text{b) } P(A) & \& \text{c) } P(B) \\ \text{d) } P(A | B) & \& \text{e) } P(\bar{A} \cap \bar{B}) & \& \text{f) } P(B | A) \end{array}$$

ب- تحقق إن كان الحادثان A و B مستقلين أم لا.

٥- أثبت أن تقاطع أية أسرة غير خالية من الجبور فوق Ω هي من جديد جبر على Ω .

٦- لتكن لدينا $\{\mathcal{A}_i : i \in I\}$ أسرة عدودة من الجبور فوق Ω ، فعندئذ أثبت أنه يكون $\bigcup_{i \in I} \mathcal{A}_i$ جبراً فوق Ω إذا كان من أجل أي

جبرين \mathcal{A}_ℓ و \mathcal{A}_m يوجد جبر \mathcal{A}_k بحيث يكون $\mathcal{A}_k \supseteq \mathcal{A}_\ell \cup \mathcal{A}_m$.

٧- لنفترض أنه لدينا بطاقات لعب مكوّن من 52 بطاقة، وأننا قمنا بخلط هذه البطاقات جيداً، ومن ثمّ نسحب أربع بطاقات دفعة

واحدة من هذه البطاقات، فما هو احتمال:

أ- أن تكون البطاقات من أنواع مختلفة؟

ب- أن تكون البطاقات من نوع واحد؟

ج- أن يكون لدينا بطاقتان من كل لون؟

د- أن تكون البطاقات من ألوان مختلفة؟

٨- لنفترض أنه لدينا بطاقات لعب مكوّنة من 52 بطاقة، وأننا قمنا بخلط هذه البطاقات جيداً، ومن ثمّ نسحب أربع بطاقات واحدة

تلو الأخرى من هذه البطاقات، فما هو احتمال:

أ- أن تكون البطاقات من أنواع مختلفة؟

ب- أن تكون البطاقات من نوع واحد؟

ج- أن يكون لدينا البطاقتان الأوليان حمراوين؟

د- أن يكون لدينا بطاقة حمراء ثمّ سوداء ثمّ حمراء وأخيراً سوداء؟

٩- لنأخذ تجربة إلقاء قطعة نقود متوازنة لأربع مرّات متتالية، فعندئذٍ اجب عما يلي:

أ- عين الفضاء الاحتمالي لهذه التجربة العشوائية.

ب- احسب احتمال الحصول على ثلاث صور فقط.

ج- احسب احتمال الحصول على صورتين متتاليتين.

د- هل حادث الحصول على صورتين متتاليتين مستقل عن حادث الحصول على شعارين متتاليتين؟

هـ- ما هو احتمال الحصول على صورتين متتاليتين علماً أنّنا قد حصلنا على صورتين؟

١٠- لنأخذ تجربة إلقاء قطعة نقود متوازنة لأربع مرّات متتالية، ولتكن A ، B و C هي حوادث الحصول على صورتين متتاليتين في الرمية

الأولى، والثانية، والثالثة على الترتيب، فعندئذٍ ابيّن أن كانت هذه الحوادث مستقلة عشوائياً أم لا؟

١١- لنأخذ تجربة إلقاء حجر نرد متوازن لمرتين متتاليتين، فعندئذٍ:

أ- عين الفضاء الاحتمالي لهذه التجربة العشوائية.

ب- احسب احتمال أن يكون مجموع الرقمين الظاهرين للأعلى أصغر من 6.

ج- احسب احتمال أن يكون الرقمين الظاهرين للأعلى غير متساويين.

د- ما هو احتمال الحصول على رقمين متتاليين؟

هـ- ما هو احتمال أن يكون مجموع الرقمين الظاهرين للأعلى يساوي 10 علماً أنّنا قد حصلنا على مجموع أكبر من 7؟

و- هل حادث الحصول على الرقم 5 في الرمية الأولى مستقل عن حادث الحصول على الرقم 5 في الرمية الثاني؟

ز- لو أخذنا تجربة إلقاء حجري نرد متوازنين وغير متميّزين لمرة واحدة فقط، فهل تتغيّر نتائج الطلبات السابقة، ولماذا؟

١٢- لنأخذ تجربة إلقاء حجري نرد متوازنين ومتميّزين لمرة واحدة فقط، فعندئذٍ اجب عما يلي:

أ- احسب احتمال أن يكون مجموع الرقمين الظاهرين للأعلى أكبر من 6.

ب- احسب احتمال أن يكون الرقمين الظاهرين للأعلى متساويين.

ج- ما هو احتمال الحصول على رقمين غير متتاليين؟

- د- ما هو احتمال أن يكون مجموع الرقمين الظاهرين للأعلى أصفر من 8 علماً أننا قد حصلنا على مجموع أصغر من 10؟
- هـ- هل حادث الحصول على الرقم 3 في الرمية الأولى مستقل عن حادث الحصول على الرقم 2 في الرمية الثانية؟
- ١٣- في صندوق يوجد 20 كرة متماثلة منها 13 كرة حمراء و 5 كرات بيضاء والباقي زرقاء. قمنا بسحب عشوائي لثلاث كرات في آن واحد من هذا الصندوق دون رؤيتها، والمطلوب:
- أ- ما هو احتمال أن تكون الكرات الثلاث من ألوان مختلفة؟
- ب- ما هو احتمال أن تكون الكرات من لون واحد؟
- ج- ما هو احتمال أن يكون لكرتين اللون نفسه والثالثة من لون آخر؟
- ١٤- في فصل دراسي يوجد 35 طالباً منهم تسعة طلاب متميزين، وأردنا أن نُشكّل فريقاً مكوناً من خمسة طلاب لمسابقة تقام بين مدارس المدينة، فإذا أخذنا خمسة طلاب دفعة واحدة من هذا الفصل وبشكل عشوائي، فعندئذ:
- أ- ما هو احتمال أن يكون في هذا الفريق ثلاثة طلاب متميزين؟
- ب- ما هو احتمال أن يكون جميع عناصر اللجنة من الطلاب المتميزين؟
- ج- ما هو احتمال أن يكون في هذا الفريق طالبان متميزان على الأكثر؟
- ١٥- لدينا في جهاز m دارة (دائرة كهربائية) تولّد عشوائياً إشارات منطقية متماثلة وباحتمال نفسه، فلو افترضنا أنه لدينا n إشارة (مع $1 < n < m$) فما هو احتمال أن تكون إشارتان على الأقل من هذه الإشارات قد ولّدت من دارة واحدة؟
- ١٦- لنفترض أنه لدينا صندوق M يحوي كرة متماثلة تماماً (أي لها جميعاً النصيب نفسه في السحب) ومرقمة من 1 وحتى M من بينها يوجد n كرة مرقمة بأعداد إضافية من 1 وحتى n علماً أن $2n \leq M$ ، ولنفترض أن شخصاً ما قام بسحب n كرة دفعة واحدة من الكرات التي في الصندوق، فعندئذ:
- أ- ما هو احتمال الحصول على كرة واحدة على الأقل دون عليها رقم إضافي من بين الكرات الـ n التي قام بسحبها؟
- ب- إذا كان $M = n^2$ ، فما هو احتمال أن يكون قد حصل على كرة واحدة على الأقل دون عليها رقم إضافي من الكرات الـ n التي قام بسحبها؟
- ج- إذا تركنا قيمة n في الطلب السابق تسعى إلى اللانهاية، فما هي القيمة التي سيأخذها الاحتمال في الطلب السابق؟
- ١٧- اتفق شخصان X و Y على الالتقاء في مكان محدد وخلال فترة زمنية معينة $[0, t]$ (حيث t مقدرة بالدقيقة)، وبحيث إنه إذا وصل الشخص الأول X إلى المكان المحدد ينتظر k دقيقة، وينصرف في حال عدم وصول الشخص الثاني Y ، وأما إذا وصل Y للمكان المحدد فإنه ينتظر ℓ دقيقة، وينصرف في حال عدم وصول X ، مع العلم أن قيمة $0 < k \leq t$ ، فعندئذ المطلوب:
- أ- ما هو احتمال وصول X قبل Y ؟
- ب- ما هو احتمال التقاء X مع Y ؟
- ج- بفرض أنه تم الالتقاء فما هو احتمال وصول X قبل Y ؟
- ١٨- لنفترض أنه لدينا جسيم يتحرك بسرعة منتظمة ومستقيمة وبشكل مواز لمحور الزمن oT وأنه خلال كل واحدة زمن (ولكن الثانية مثلاً) يقوم هذا الجسيم بقفزة نحو الأعلى أو نحو الأسفل بمقدار وحدة طول (ولكن ستمثراً مثلاً) وباحتمال قدره $0 < p < 1$ و $q = 1 - p$ على الترتيب (إن حركة هذا الجسيم تُعرف باسم الخطى العشوائية Random Walk). فإذا أنجز هذا الجسيم n قفزة، فعندئذ عيّن الفضاء الاحتمالي لهذه التجربة العشوائية؟



١٩- لنفترض أنه لدينا بطاقات لعب Playing Cards مكونة من 52 بطاقة. نقوم بخلط البطاقات جيداً ومن ثمَّ نسحب خمس بطاقات، فما هو احتمال أن نحصل على العرض الجانبي للبطاقات المسحوبة إذا كنا:

أ- قد سحبنا البطاقات دفعة واحدة؟

ب- قد سحبنا البطاقات واحدة تلو الأخرى؟

٢٠- يقوم شخص برمي سهم على لوحة مربعة طول ضلعها 56 سم، وفي أوسطها مجموعة من الدوائر مركزها مبدأ الإحداثيات (كما هو موضح جانباً)،


فإذا علمت أن لجميع نقاط لوحة النصب نفسه في الإصابة، وأنه سيصيب نقطة ما من هذه اللوحة بكل تأكيد، وأن أنصاف أقطار هذه الدوائر (مقدرة بـ سم) هي: 1، 10، 11، 20، 21 و 23، فعندئذ:

أ- ما هو احتمال أن يصيب القرص الدائري الصغير الذي في المركز؟

ب- ما هو احتمال أن يصيب الشريط الدائري الأوسط (قطره الخارجي 11 سم)؟

ج- ما هو احتمال أن يصيب الشريط الدائري الذي قطره الخارجي 20 سم؟

د- ما هو احتمال ألا يصيب أية نقطة من القرص الدائري؟



الفصل الخامس

المتغيرات العشوائية وتوزيعاتها الاحتمالية

RANDOM VARIABLE AND THEIR PROBABILITY DISTRIBUTIONS

لقد قدمنا في الفصل السابق مفهوم الفضاء الاحتمالي $[\Omega, \mathcal{A}, P]$ وكيفية تعيينه، ومن ثم حساب احتمالات لحوادث تتعلق بتجربة عشوائية، وبعد ذلك انتقلنا إلى الاحتمالات الشرطية واستقلال الحوادث. لكن الوقوف عند هذه الدراسات لا تفي بمتطلبات الكثير من الظواهر الطبيعية والتقنية الموجودة في الواقع حيث تظهر لنا حوادث تنتج عن دوال معرفة على مجموعة نتائج تجربة عشوائية. إن الكائن الرياضي الذي يعالج هذه المسألة يُعرف بالعنصر العشوائي (وكحالة خاصة منه المتغير العشوائي) الذي سيكون موضع اهتمامنا في هذا الفصل. إن مفهوم العنصر العشوائي يُعدّ واحداً من أهم المفاهيم المتعلقة بنظرية الاحتمالات، ولكن وكما ذكرنا قبل قليل، فإنّ جلّ دراستنا في هذا الفصل والفصول القادمة أيضاً ستكون معتمدة على مفهوم المتغير العشوائي، ولذلك سنبدأ في توضيح وتعريف المتغير العشوائي ومن ثمّ نعرّج بشكل سريع وموجز على مفهوم العنصر العشوائي.

(٥, ١) المتغيرات العشوائية

Random Variables

في الحقيقة يقوم المتغير العشوائي بدور مركزي في نظرية الاحتمالات وتطبيقاتها، وذلك لأنّ عدداً كبيراً جداً من المشاهدات والملاحظات العملية والطبيعية على حدّ سواء يمكن وصفها من خلال متغيرات عشوائية أو لأسر (قد تكون عدودة- أي قابلة للعد- أو غير عدودة) من المتغيرات العشوائية، ولهذا يأتي هذا المفهوم في مقدمة الدراسات للنظرية الحديثة للاحتتمالات. لكن قبل تقديم التعريف لهذا المفهوم سنقدّم توضيحاً لكيفية نشوء مفهوم المتغير العشوائي من خلال مثال عملي ومألوف والمتمثل بتجربة قذف قطعة نقود لثلاث مرات متتالية.

لنأخذ تجربة قذف قطعة نقود متوازنة لثلاث مرّات متتالية، فعندئذ الفضاء الاحتمالي $[\Omega, \mathcal{A}, P]$ لهذه التجربة العشوائية له المكونات الآتية:

$$\Omega = \{HHH, HHT, HTH, THH, HTT, THT, TTH, TTT\} \quad \& \quad \mathcal{A} = 2^\Omega$$


$$\text{And } P(A) = \sum_{\omega \in A} P(\{\omega\}) \quad ; \forall A \in \mathcal{A}$$

فلو افترضنا أنّ A هو الحادث الذي يُعبّر عن حصولنا على صورتين في الرميات الثلاث، أي إنّ:

$$A = \{HHT, HTH, THH\}$$

فعندئذ نلاحظ أنّ لا أهمية لتوضعات الصور خلال هذه الرميات، وهذا يعني أنّ في مثالنا هذا لا نهتم في أية قذفة من هذه القذفات سنحصل على الصورة، وإنّا الذي يهمنا حقاً هو إن كنّا سنحصل في نهاية القذفات الثلاث على صورتين فقط؛ ولذلك دراسة كل حادث

ابتدائي ω من Ω لم تعد مهمة بالنسبة إلينا في هذه الحالة. الآن لو أمعنا النظر في عبارة الحصول على صورتين فقط، فإنه قد يتبادر إلى ذهننا مباشرة فكرة استخدام الأعداد للتعبير عن الحادث A وذلك من خلال عملية إرفاق كل حادث ابتدائي ω من Ω بعدد يُعبّر عن عدد الصور في هذا الحادث الابتدائي، فيكون لدينا في هذه الحالة المجموعة $\{2\}$ توافق الحادث A (انظر الشكل الآتي).



في الحقيقة إن عملية الإرفاق هذه ما هي إلا تطبيق X Map معرف على Ω ويأخذ قيمه في مجموعة الأعداد الحقيقية R كما يوضحه لنا الشكل (١، ٥) الآتي، وكما هو واضح فإن هذا التطبيق وحيد القيمة ومعين بشكل وحيد وفقاً للطريقة التي قدم بها، وهذا يعني أن التطبيق X هو في الواقع عبارة عن دالة حقيقية معرفة على Ω .

الآن لو رمزنا لمجموعة قيم التطبيق X بـ Ω^* فإنه سيكون لدينا $\Omega^* = \{0, 1, 2, 3\}$ ومنه نلاحظ أن كل عنصر من Ω^* هو من جديد حادث ابتدائي لأن ظهور القيم 0، 1، 2 و 3 في Ω^* عشوائي، وعشوائيتها تنتج من عشوائية الحوادث الابتدائية في Ω .

الشكل (١، ٥)

مما سبق يمكننا القول:

إن التطبيق X قام بنقل التجربة العشوائية التي مجموعة نتائجها Ω إلى تجربة عشوائية أخرى مجموعة نتائجها Ω^* التي عناصرها من R ، ولكن حتى تكون هذه التجربة العشوائية الجديدة (التي مجموعة نتائجها Ω^*) ممثلة للتجربة العشوائية الأصل (مكافئة لها) يجب أن يكون التطبيق X أميناً في (أو محافظاً على) نقل الحوادث أيضاً، فلو كان \mathcal{A}^* هو σ -جبر فوق Ω^* (حيث يؤخذ $\mathcal{A}^* = \Omega^* \cap R$) فإن ذلك يستوجب أن تكون الصورة العكسية لأي حادث B من \mathcal{A}^* وفقاً للتطبيق X هي من جديد حادث في Ω ، فعلى سبيل المثال لو أخذنا $B = \{2\}$ من \mathcal{A}^* في مثالنا المذكور آنفاً فإنه يجب أن يكون الحادث الآتي:

$$X^{-1}(\{B\}) = X^{-1}(\{2\}) = \{\omega \in \Omega; X(\omega) = 2\} = \{HHT, HTH, THH\}$$

هو حادث من \mathcal{A} ، وهذا مُحقق لأن الحادث $\{HHT, HTH, THH\}$ ينتمي إلى \mathcal{A} كما نعلم، ولكن تحقق هذه العلاقة فقط لا يكفي، إذ إننا ذكرنا بأنه يجب تحقق هذه العلاقة من أجل أي حادث B من \mathcal{A}^* . إن التطبيقات التي تحقق مثل هذه الخاصية تدعى متغيرات عشوائية، وأصل التسمية تعود إلى كون القيم التي يأخذها التطبيق X (وهو دالة في مثالنا هذا) تتغير بشكل عشوائي. إن التعريف الرياضي الدقيق لهذا المفهوم تقدمه لنا الفقرة الآتية.

(١، ٥) تعريف (المتغير العشوائي)

ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتمالياً معطى، و $[R, \mathcal{R}]$ فضاء مقيساً، ولنأخذ $X: \Omega \rightarrow R$ تطبيقاً ما، فإذا كان من أجل أية مجموعة بوريلية $B \in \mathcal{R}$ لدينا:

$$X^{-1}(B) = \{\omega \in \Omega; X(\omega) \in B\} \in \mathcal{A} \quad [5,1]$$

فعندئذ يُقال عن X إنه متغير عشوائي فوق الفضاء الاحتمالي $[\Omega, \mathcal{A}, P]$.

إن العلاقة السابقة تعني (في نظرية القياس) أن التطبيق X قياساً (أو مقيساً أو قابلاً للقياس Measurable) بالنسبة إلى \mathcal{A} و \mathcal{R} ، وهذا يعني أن المتغيرات العشوائية في حقيقتها هي تطبيقات قياس Measurable Maps.

في الجوانب التطبيقية يعد تحقيق العلاقة [5,1] ليس سهلاً في معظم الحالات، وفي حال كان ذلك ممكناً فهو شاق جداً، ولذلك قُدمت اختبارات لتحديد إن كان تطبيق X فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ متغيراً عشوائياً أم لا.

إن المبرهنة الآتية تقدم لنا أحد هذه الاختبارات، علماً أننا سنقبلها دون برهان لأن برهانها يقع في نطاق نظرية القياس.

(١, ١, ٥) مبرهنة

ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتمالي معطى، ولنأخذ $X: \Omega \rightarrow \mathbb{R}$ تطبيقاً حقيقياً معرفاً على Ω بحيث $\omega \mapsto X(\omega)$ ، فإذا كان:

$$\{\omega \in \Omega; X(\omega) < x\} \in \mathcal{A} \quad ; \forall x \in \mathbb{R} \quad [5,2-a]$$

فعندئذ يكون X متغيراً عشوائياً فوق $[\Omega, \mathcal{A}, P]$.

(٢, ١, ٥) ملاحظات

١- فيما بعد سنعتمد على الاختبار الوارد في المبرهنة السابقة لتبيان إن كان تطبيق X فوق فضاء $[\Omega, \mathcal{A}, P]$ متغيراً عشوائياً أم لا، وقد وقع اختيارنا على هذا الاختبار بسبب حاجتنا للحادث $\{\omega \in \Omega; X(\omega) < x\}$ في تعريف دالة التوزيع الاحتمالية لمتغير عشوائي X لاحقاً.

٢- بما أن $\{\omega \in \Omega; X(\omega) < x\} = X^{-1}((-\infty, x))$ فإن الشرط السابق [5,2-a] يكافئ الشرط الآتي أيضاً:

$$X^{-1}((-\infty, x)) \in \mathcal{A} \quad ; \forall x \in \mathbb{R} \quad [5,2-b]$$

٣- على سبيل الاختصار والتبسيط يكتب في كثير من الحالات $P(X < x)$ عوضاً عن:

$$P(\{\omega \in \Omega; X(\omega) < x\})$$

وعندما نكتب الصيغة المفصلة إنما نقصد بذلك التذكير بها أو لضرورة تمليلها طبيعة العرض للعلاقة التي هي قيد الدراسة.

٤- لكي نتجنب سوء الفهم الذي يمكن أن ينشأ عن مصطلح المتغير العشوائي كدالة نود أن نشير هنا إلى أن المتغير العشوائي X كدالة إنما يعني أنه لدى متغيرات مستقلة ω من Ω مُعطاة تكون القيم $X(\omega)$ وحيدة التعيين، وأن قبول هذه الدالة كمتغير عشوائي يتوقف على اختيار المتغيرات المستقلة ω من Ω ، وعلى اختيار الـ σ -جبر \mathcal{A} ، والأمثلة الآتية توضح ذلك.

(٣, ١, ٥) أمثلة

١- ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتمالي معطى، و X تطبيقاً حقيقياً معرفاً على Ω من خلال العلاقة الآتية:

$$X(\omega) = c \quad ; \forall \omega \in \Omega$$

علماً أن c عدد حقيقي ثابت (أي إن X هو التطبيق الثابت)، فعندئذ نجد أن هذا التطبيق هو متغير عشوائي فوق $[\Omega, \mathcal{A}, P]$ وذلك لأن:

$$\{\omega \in \Omega; X(\omega) < x\} = \begin{cases} \emptyset & \text{for } x \leq c \\ \Omega & \text{for } x > c \end{cases}$$

حيث نعلم أن \emptyset من Ω هي عناصر من \mathcal{A} دوماً لأن \mathcal{A} هو σ -جبر فوق Ω . إذاً التطبيق X هو متغير عشوائي فوق $[\Omega, \mathcal{A}, P]$ ، ويدعى متغير عشوائي وحيد النقطة (أو الوحيد القيمة أو الثابت) فوق $[\Omega, \mathcal{A}, P]$ أيضاً. لاحظ هنا أنه حتى لو أخذنا \mathcal{A} في نموذج الفضاء الاحتمالي $[\Omega, \mathcal{A}, P]$ هو الجبر الضعيف $\mathcal{A} = \{\emptyset, \Omega\}$ ، فإن التطبيق X المعطى في هذا المثال هو متغير عشوائي فوق $[\Omega, \mathcal{A}, P]$ ، ولكن يجب الانتباه إلى أن هذا الطرح ليس صحيحاً في الحالة العامة، والمثال التالي يوضح لنا ذلك.

٢- ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتمالي معطى على النحو الآتي:

$$\Omega = \{\omega_1, \omega_2\} \quad \& \quad \mathcal{A} = 2^\Omega$$

$$P(A) = p \cdot \delta_{\omega_1}(A) + q \cdot \delta_{\omega_2}(A) \quad ; \forall A \in \mathcal{A}, \quad p + q = 1.$$

أي إنه لدينا $P(\{\omega_1\}) = p$ و $P(\{\omega_2\}) = q$ (راجع المبرهنة (٣-٤-١-٤) في الفصل السابق)، ولنأخذ X تطبيقاً حقيقياً معرفاً على Ω كما يلي:

$$X(\omega) = \begin{cases} 0 & \text{for } \omega = \omega_2 \\ 1 & \text{for } \omega = \omega_1 \end{cases}$$

ولنتبين إن كان هذا التطبيق هو متغير عشوائي فوق $[\Omega, \mathcal{A}, P]$ أم لا. من أجل ذلك لدينا:

$$\{\omega \in \Omega ; X(\omega) < x\} = \begin{cases} \emptyset & \text{for } x \leq 0 \\ \{\omega_2\} & \text{for } 0 < x \leq 1 \\ \{\omega_1, \omega_2\} = \Omega & \text{for } x > 1 \end{cases}$$

ولكن نعلم أن $\{\omega_2\}$ ، \emptyset و Ω هي عناصر من \mathcal{A} ، ومن ثم التطبيق X هو متغير عشوائي فوق $[\Omega, \mathcal{A}, P]$.

لاحظ أنه لو أخذنا $\mathcal{A} = \{\emptyset, \Omega\}$ في نموذج الفضاء الاحتمالي $[\Omega, \mathcal{A}, P]$ (وهو σ -جبر فوق Ω كما نعلم)، فعندئذ التطبيق X ليس متغيراً عشوائياً فوق $[\Omega, \mathcal{A}, P]$ لأن $\{\omega_2\}$ ليس عنصراً من \mathcal{A} في هذه الحالة. لذلك عندما نريد تبيان إن كان تطبيق X هو متغير عشوائي فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ فإنه علينا الانتباه إلى σ -جبر الذي نتعامل معه.

كتطبيق على هذا المثال لنأخذ تجربة قذف قطعة نقود (ليس بالضرورة أن تكون متوازنة) لمرة واحدة فقط، وليكن X تطبيقاً حقيقياً معرفاً على مجموعة نتائج هذه التجربة العشوائية كما يلي:

$$X(\omega) = \begin{cases} 0 & \text{for } \omega = H \\ 1 & \text{for } \omega = T \end{cases}$$

فنجده أن:

$$\{\omega \in \Omega ; X(\omega) < x\} = \begin{cases} \emptyset & \text{for } x \leq 0 \\ \{H\} & \text{for } 0 < x \leq 1 \\ \{H, T\} = \Omega & \text{for } x > 1 \end{cases}$$

وبما أن $\{H\}$ ، \emptyset و Ω هي عناصر من $\mathcal{A} = 2^\Omega$ فإن ذلك يعني أن التطبيق X هو متغير عشوائي فوق الفضاء الاحتمالي لهذه التجربة العشوائية.

٣- ليكن $[\Omega, \mathcal{A}, P]$ هو الفضاء الاحتمالي لتجربة إلقاء حجر نرد متوازن لمرة متتاليتين، أي إن:

$$\Omega = \{\omega = (\omega_1, \omega_2) ; \omega_1, \omega_2 \in \{1, 2, \dots, 6\}\} \quad \& \quad \mathcal{A} = 2^\Omega \quad \& \quad P(A) = \sum_{\omega_1, \omega_2=1}^6 \frac{1}{36} \delta_{(\omega_1, \omega_2)}(A) ; \forall A \in \mathcal{A}$$

وليكن X تطبيقاً معرفاً فوق Ω من خلال العلاقة الآتية:

$$X(\omega) = \begin{cases} 0 & \text{for } \omega_1 + \omega_2 < 10 \\ 1 & \text{for } \omega_1 + \omega_2 \geq 10 \end{cases}$$

فنجده أن هذا التطبيق هو متغير عشوائي فوق $[\Omega, \mathcal{A}, P]$ وذلك لأن:

$$\{\omega \in \Omega ; X(\omega) < x\} = \begin{cases} \emptyset & \text{for } x \leq 0 \\ \{(\omega_1, \omega_2) \in \Omega ; \omega_1 + \omega_2 < 10\} & \text{for } 0 < x \leq 1 \\ \Omega & \text{for } x > 1 \end{cases}$$

حيث نعلم أن \emptyset ، Ω من \mathcal{A} دوماً وكذلك $\{(\omega_1, \omega_2) \in \Omega ; \omega_1 + \omega_2 < 10\}$ هو عنصر من 2^Ω أيضاً.

٤- يقف شخص على شرفة بناء شاهق (مرتفع جداً) مبني على حافة نهر ضيق المسار بحيث يبدو للشخص على شكل خط مستقيم. يلقي هذا الشخص بحصى على النهر بحيث يمكنه أن يمسح جزءاً من طول النهر المحدود بنقطتين a و b ، علماً أن $-\infty < a < b < \infty$ ، فلو افترضنا أن الحصى الملقاة ستصيب نقطة ما من النهر (نقطة من الفترة $[a, b]$) حتماً، وكذلك لجميع نقاط هذه الفترة النصيب نفسه في الإصابة، فعندئذ سيكون الفضاء الاحتمالي $[\Omega, \mathcal{A}, P]$ لهذه التجربة العشوائية معين من خلال المعطيات الآتية:

$$\Omega = [a, b] \quad \& \quad \mathcal{A} = \mathbb{R} \cap [a, b] \quad \& \quad P(A) = \frac{1}{b-a} \int_A dx \quad ; \forall A \in \mathcal{A}$$

وليكن X تطبيقاً حقيقياً معرفاً على Ω كما يلي:

$$X(\omega) = \omega \quad ; \forall \omega \in \Omega$$

ف نجد أن هذا التطبيق (التطبيق المطابق على Ω) هو متغير عشوائي فوق $[\Omega, \mathcal{A}, P]$ وذلك لأن:

$$\{\omega \in \Omega ; X(\omega) < x\} = \begin{cases} \emptyset & \text{for } x \leq a \\ [a, x) & \text{for } a < x \leq b \\ [a, b] = \Omega & \text{for } x > b \end{cases}$$

حيث نعلم أن \emptyset و Ω من \mathcal{A} دوماً، والفترات $[a, x)$ مع $b \geq x$ هي مجموعات بوريلية من \mathbb{R} واقعة في الفترة $[a, b]$ ، ومن ثم فإن $[a, x)$ عنصر من \mathcal{A} أيضاً.

(٤، ١، ١، ٥) ملاحظات

١- بالعودة إلى المثال / ١ / من الفقرة السابقة نلاحظ أن:

$$P(X = c) = P(\{\omega \in \Omega ; X(\omega) = c\}) = P(\Omega) = 1$$

ولذلك يُقال إن X متغير عشوائي ثابت باحتمال يساوي الواحد (أو تقريباً أكيد) أيضاً، ويكتب ذلك على النحو الآتي:

$$X \stackrel{a.s.}{=} c \quad \text{or} \quad X = c \quad ; \text{a.s.} \quad \text{or} \quad X = c \quad \text{almost all } \omega \in \Omega$$

علماً أن (a.s.) هي اختصار لـ Almost Sure، ولكن يجب الانتباه هنا إلى أن العكس ليس صحيحاً في الحالة العامة، بمعنى أنه إذا كان لدينا $X \stackrel{a.s.}{=} c$ فإن ذلك لا يعني أن $X(\omega) = c$ من أجل كل $\omega \in \Omega$ ، وذلك لأنه من الممكن أن يوجد حادث $A \in \mathcal{A} \neq \emptyset$ بحيث $X(\omega) \neq c$ من أجل كل أي $\omega \in \Omega$ ، ولكن في هذه الحالة يجب أن يكون $P(A) = 0$ ، أي إن الحادث A في هذه الحالة هو حادث شبه مستحيل.

٢- إذا كان X و Y متغيرين عشوائيين فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، وكان من أجلهما لدينا:

$$P(X = Y) = P(\{\omega \in \Omega ; X(\omega) = Y(\omega)\}) = 1 \quad [5,3]$$

فعندئذ يقال عن هذين المتغيرين العشوائيين إنهما متكافئان ويكتب ذلك بالشكل $X \approx Y$ ، أو يُقال إنهما متساويان باحتمال يساوي الواحد، ويكتب ذلك على النحو الآتي:

$$X \stackrel{a.s.}{=} Y \quad \text{or} \quad X = Y \quad \text{almost all } \omega \in \Omega \quad [5,4]$$

وبناء على ذلك فإنه يمكن النظر إلى القيم الثابتة من \mathbb{R} على أنها متغيرات عشوائية ثابتة معرفة على Ω وتأخذ قيمتها نفسها باحتمال يساوي الواحد.

٤- كما رأينا في الملاحظة السابقة / ٢ /، فإن المتغيرات العشوائية تتساوى فيما بينها على حوادث شبه أكيدة (أو على الحادث الأكيد

في بعض الحالات الخاصة) وذلك بسبب تحقق العلاقة [5,3]، ولكن على سبيل التبسيط والاختصار سنكتب $X=Y$ دون أن نذكر عبارة "باحتمال يساوي الواحد"، حيث يجب أن يفهم من هذه الكتابة دوماً أنها متساويان باحتمال يساوي الواحد.

لقد ذكرنا سابقاً أن مفهوم المتغير العشوائي ما هو إلا حالة خاصة من مفهوم أكثر شمولية يُعرف باسم **العنصر العشوائي** Random Element، ويقدمه لنا التعريف الآتي.

(٥, ١, ٢) تعريف (العنصر العشوائي Random Element)

ليكن $[\Omega, \mathcal{A}, P]$ فضاءً احتمالياً و $[G, \mathcal{G}]$ فضاءً مقيساً ذو طبيعة ما، ولنأخذ $X: \Omega \longrightarrow G$ تطبيقاً قيوساً بالنسبة إلى \mathcal{A} و \mathcal{G} ، فعندئذ يُسمى التطبيق X **عنصراً عشوائياً** فوق الفضاء الاحتمالي $[\Omega, \mathcal{A}, P]$ ، أو يُقال إن X هو متغير عشوائي فوق الفضاء الاحتمالي $[\Omega, \mathcal{A}, P]$ وبقیم في الفضاء المقيس $[G, \mathcal{G}]$. أي إن:

$$X \text{ is a random element} \Leftrightarrow X^{-1}(B) \in \mathcal{A} ; \forall B \in \mathcal{G} \quad [5,5]$$

عادةً تُخصّص كلمة متغير عشوائي (دون ذكر بقيم في الفضاء المقيس $[G, \mathcal{G}]$) للعناصر العشوائية التي تأخذ قيمها في $[\mathbb{R}, \mathcal{R}]$ فقط، وفيما عدا ذلك يكون لـ X تسميات أخرى حسب بنية الفضاء المقيس $[G, \mathcal{G}]$ ، والأمثلة الآتية تعرض لنا بعض النماذج الخاصة من العناصر العشوائية.

(٥, ١, ٢, ١) أمثلة

ليكن $[\Omega, \mathcal{A}, P]$ فضاءً احتمالياً و $[G, \mathcal{G}]$ فضاءً مقيساً، ولنأخذ $X: \Omega \longrightarrow G$ تطبيقاً قيوساً بالنسبة إلى \mathcal{A} و \mathcal{G} ، فعندئذ:

١- إذا أخذنا $[G, \mathcal{G}] = [\mathbb{R}, \mathcal{R}]$ فإن X يُدعى **متغيراً عشوائياً** Random Variable (كما نوهنا بذلك قبل قليل).

٢- إذا أخذنا $[G, \mathcal{G}] = [\mathbb{R}^n, \mathcal{R}^n]$ فإن X يُدعى **متجهاً عشوائياً** بعده n (n -Dimensional Random Vector)، وسنرمز له بـ X_n .

٣- إذا أخذنا $[G, \mathcal{G}] = [\mathbb{C}, \mathcal{C}]$ فإن X يُدعى **متغيراً عشوائياً عقدياً** Complex Random Variable، علماً أن \mathbb{C} هي مجموعة الأعداد العقدية (أو المركبة) و \mathcal{C} هو أصغر σ -جبر على \mathbb{C} الذي يحوي المجموعات ذات الشكل الآتي:

$$\{z \in \mathbb{C} ; z = x + iy ; a_1 \leq x < b_1 \text{ \& } a_2 \leq y < b_2 \text{ with } a_1, a_2, b_1, b_2 \in \mathbb{R}\}$$

٤- إذا أخذنا $[G, \mathcal{G}] = [\mathbf{M}, \mathcal{M}]$ علماً أن الفضاء المقيس $[\mathbf{M}, \mathcal{M}]$ يبنى على النحو الآتي:
نأخذ $[X, \rho]$ فضاءً مترياً فضولاً (قابلاً للفصل Separable) وتاماً، وليكن \mathcal{X} أصغر σ -جبر على X . كذلك لرمز بـ \mathbf{M} لمجموعة كل القياسات φ على $[X, \mathcal{X}]$ بحيث يكون من أجل كل $A \in \mathcal{X}$ لدينا $\varphi(A) \in \overline{\mathbb{N}}$ ، ومن ثم نأخذ \mathcal{M} هو أصغر σ -جبر على \mathbf{M} الذي من أجله التطبيقات الآتية قيوسة من أجل كل $A \in \mathcal{X}$:

$$\Delta_A : \mathbf{M} \longrightarrow \overline{\mathbb{N}} ; \varphi \mapsto \Delta_A(\varphi) := \varphi(A)$$

عندئذ يُدعى العنصر العشوائي X **طورياً نقطياً** Point Process.

٥- إذا أخذنا $[G, \mathcal{G}] = [\mathbb{N}, \mathcal{N}]$ علماً أن الفضاء المقيس $[\mathbb{N}, \mathcal{N}]$ يُشكّل على النحو الآتي:
ليكن $[\Omega, \mathcal{A}, P]$ فضاءً احتمالياً و $[S, \mathcal{S}]$ فضاءً مقيساً، ولتكن N مجموعة كل **قوانين التوزيع** (سنأتي على شرح هذا المفهوم لاحقاً في هذا الفصل) على \mathcal{S} ، وليكن \mathcal{N} هو أصغر σ -جبر فوق N الذي من أجله تكون التطبيقات Δ_B الآتية قيوسة من أجل كل $B \in \mathcal{S}$:

$$\Delta_B : \mathbf{N} \longrightarrow \mathbb{R} ; P \mapsto \Delta_B(P) := P(B)$$

عندئذ يُسمى العنصر العشوائي X **نواة عشوائية** Random Kern.

٦- إذا أخذنا $[G, \mathcal{G}] = [F, \mathcal{F}]$ علماً أن الفضاء المقيس $[F, \mathcal{F}]$ يبنى على النحو الآتي:

ليكن F صف كل المجموعات الجزئية المغلقة في \mathbb{R}^n ، ومن ثم نأخذ \mathcal{F} هو أصغر σ -جبر فوق F والحاوي على كل المجموعات ذات الشكل الآتي:

$$A_K := \{A \in \mathcal{F} ; A \cap K \neq \emptyset\} ; \forall K \in \mathcal{K}$$

علماً أن \mathcal{K} يرمز لصف كل المجموعات المتراسة Compact Sets في \mathbb{R}^n ، فعندئذ يدعى العنصر العشوائي X **مجموعة مغلقة عشوائية** Random Closed Set.

سنقدم فيما يلي أحد المفاهيم المهمة التي تستخدم في تقديم العديد من صيغ الدوال والمتغيرات العشوائية على حد سواء (من أجل الاطلاع على خصائصها راجع تعريف الدالة المميزة لمجموعة في الملحق A).

(٥, ١, ٣) الدالة المميزة لحادث Indicator Function of an Event

تعريفها: من أجل Ω مجموعة نتائج تجربة عشوائية ما، فإن **الدالة المميزة لمجموعة** $\Omega \supseteq A$ هي دالة حقيقية I_A معرفة على Ω كما يلي:

$$I_A(\omega) = \begin{cases} 1 & \text{for } \omega \in A \\ 0 & \text{for } \omega \notin A \end{cases} \quad [5,6]$$

(٥, ١, ٣, ١) مبرهنة

ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتمالي معطى، ولنأخذ $\Omega \supseteq A$. عندئذ تكون الدالة I_A متغيراً عشوائياً فوق $[\Omega, \mathcal{A}, P]$ **إذا وفقط** إذا كانت المجموعة A حادثاً من \mathcal{A} .
البرهان: بملاحظة أن:

$$\{\omega \in \Omega ; I_A(\omega) < x\} = \begin{cases} \emptyset & \text{for } x \leq 0 \\ \bar{A} & \text{for } 0 < x \leq 1 \\ \Omega & \text{for } x > 1 \end{cases}$$

وبما أن \mathcal{A} هو σ -جبر فوق Ω ، فإن \emptyset و Ω هي عناصر من \mathcal{A} دوماً، ولذلك تكون الدالة I_A متغيراً عشوائياً فوق $[\Omega, \mathcal{A}, P]$ **إذا وفقط** إذا كانت \bar{A} عنصراً من \mathcal{A} ، والذي يقتضي أن يكون A عنصراً من \mathcal{A} أيضاً (لأن \mathcal{A} مغلق بالنسبة إلى عملية التكميم)، ومن ثم تكون الدالة I_A متغيراً عشوائياً فوق $[\Omega, \mathcal{A}, P]$ **إذا وفقط** إذا كانت المجموعة A حادثاً من \mathcal{A} .

(٥, ١, ٤) الدوال في متغيرات عشوائية

المبرهنات الآتية تعرض لنا بعض الخصائص المهمة للمتغيرات العشوائية، حيث تستند في ادعاءاتها إلى خصائص الدوال القياسية (للاطلاع راجع الملحق B).

(٥, ١, ٤, ١) مبرهنات (تقبل دون برهان)

١- إذا كانت g دالة حقيقية معرفة على \mathbb{R} ، وكانت هذه الدالة متباينة أو مستمرة على Ω ، فعندئذ تكون هذه الدالة مقيسة بالنسبة إلى \mathcal{A} و \mathbb{R} ، ومن ثم بفرض أن X متغير عشوائي فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فإن $g(X)$ سيكون متغيراً عشوائياً فوق الفضاء الاحتمالي $[\Omega, \mathcal{A}, P]$ أيضاً.

- ٢- إذا كان Y متغيراً عشوائياً فوق فضاء احتمالي $[\mathbb{R}, \mathcal{R}, S]$ ، وبفرض أن X متغير عشوائي فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فإن التركيب $\Omega \xrightarrow{X} \mathbb{R} \xrightarrow{Y} \mathbb{R}$ هو من جديد متغير عشوائي فوق $[\Omega, \mathcal{A}, P]$ (لأن تركيب تطبيقين قيوسين هو تطبيق قيوس أيضاً).
- ٣- لتكن X_1, X_2, \dots, X_n متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فإذا كانت g دالة حقيقية معرفة على \mathbb{R}^n ومقيسة بالنسبة إلى \mathcal{R}^n و \mathcal{R} ، فعندئذ تكون الدالة $Y = g(X_1, X_2, \dots, X_n)$ مقيسة بالنسبة إلى \mathcal{A} و \mathcal{R} ، ومن ثم يكون Y متغيراً عشوائياً فوق $[\Omega, \mathcal{A}, P]$.

تسمح المبرهنة الآتية بدراسة نماذج مختلفة من المتغيرات العشوائية والتعامل مع العمليات الجبرية على المتغيرات العشوائية، وكذلك دراسة بعض الحالات الحدية لمتتاليات من المتغيرات العشوائية.

(٥, ١, ٤, ٢) مبرهنة (يترك إثبات فقراتها كتارين للقارئ)

لتكن X, Y, X_1, X_2, \dots متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ ستكون الدالة Z في الصيغ الآتية هي متغير عشوائي فوق $[\Omega, \mathcal{A}, P]$ أيضاً:

- 1) $Z = |X|$
- 2) $Z = aX + b$; $a, b \in \mathbb{R}$ and $a \neq 0$
- 3) $Z = X \pm Y$
- 4) $Z = X \cdot Y$
- 5) $Z = \frac{X}{Y}$; $Y(\omega) \neq 0$ for all $\omega \in \Omega$
- 6) $Z = \max \{X_i, X_j\}$; $i, j \in \mathbb{N}, i \neq j$
- 7) $Z = \min \{X_i, X_j\}$; $i, j \in \mathbb{N}, i \neq j$
- 8) $Z = \sup \{X_n ; n \in \mathbb{N}\}$
- 9) $Z = \inf \{X_n ; n \in \mathbb{N}\}$
- 10) $Z = \overline{\lim}_{n \rightarrow \infty} X_n = \lim_{n \rightarrow \infty} \sup_{m \geq n} X_m$
- 11) $Z = \underline{\lim}_{n \rightarrow \infty} X_n = \lim_{n \rightarrow \infty} \inf_{m \geq n} X_m$
- 12) $Z = \lim_{n \rightarrow \infty} X_n$

(٥, ٢) قانون ودالة توزيع متغير عشوائي

Distribution Law and Function of a Random Variable

من المفاهيم المهمة التي ترتبط مع مفهوم المتغير العشوائي ارتباطاً وثيقاً ومباشراً ما يُعرف باسم **قانون التوزيع** Distribution Law لمتغير عشوائي، وأهمية هذا القانون تكمن في أنه يصف التوزيع الاحتمالي لقيم المتغير العشوائي.

(٥, ٢, ١) قانون توزيع متغير عشوائي

لقد أدخل مفهوم قانون التوزيع لأول مرة من قبل الرياضياتي والفيزيائي الفرنسي **بواسون** (1781-1842) حيث قدمه كدالة احتمالية وذلك لأن القياس لم يكن مطروحاً آنذاك. أما التعريف الرياضي الدقيق لهذا الكائن فيقدمه لنا التعريف الآتي.

(١, ٢, ٥) تعريف (قانون توزيع متغير عشوائي)

ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتماليًا معطى، و $[\mathbb{R}, \mathcal{R}]$ فضاء مقيسًا، ولنأخذ $X: \Omega \rightarrow \mathbb{R}$ متغيرًا عشوائيًا، ولنضع:

$$P_X := P \circ X^{-1} \quad [5,7-a]$$

فنجدها دالة مجموعات حقيقية معرفة على \mathcal{R} ، أي إن:

$$P_X(B) = P \circ X^{-1}(B) \quad ; B \in \mathcal{R} \quad [5,7-b]$$

علمًا أن الرمز (°) يشير إلى تركيب التطبيقات، فعندئذ P_X يُسمى **قانون توزيع** Distribution Law المتغير العشوائي X .

(٢, ٢, ٥) ملاحظات

١- يُقال عن P_X إنه القياس المولد من المتغير العشوائي X ، ويمكن التحقق بسهولة من أن P_X هو قياس احتمالي على $[\mathbb{R}, \mathcal{R}]$ ، ومن ثم يكون فضاء القياس $[\mathbb{R}, \mathcal{R}, P_X]$ هو فضاء احتمالي، ويُسمى **الفضاء الاحتمالي المولد من المتغير العشوائي X** .

٢- من أجل A حادث ما من \mathcal{A} يكون لقانون توزيع المتغير العشوائي \mathbf{I}_A العرض الآتي:

$$P_{\mathbf{I}_A}(B) = \begin{cases} P(A) & \text{for } 1 \in B \\ P(\bar{A}) & \text{for } 0 \in B \\ 1 & \text{for } 0, 1 \in B \\ 0 & \text{O.W.} \end{cases}$$

(٣, ٢, ٥) أمثلة

١- بالعودة إلى المثال / ١ / من (٣, ١, ٥) نجد أن قانون توزيع المتغير العشوائي X يُعين على النحو الآتي:
من أجل أي حادث B (مجموعة بوريلية) من \mathcal{R} لدينا ما يلي:

$$P_X(B) = P(X^{-1}(B)) = \begin{cases} P(\Omega) = 1 & \text{for } c \in B \\ P(\emptyset) = 0 & \text{for } c \notin B \end{cases}$$

ومن ثم يكون لقانون توزيع هذا المتغير العشوائي العرض الآتي:

$$P_X(B) = \begin{cases} 1 & \text{for } c \in B \\ 0 & \text{for } c \notin B \end{cases} \quad ; \forall B \in \mathcal{R}$$

أو أن نقوم بعرضه من خلال العلاقة الآتية:

$$P_X(\{x\}) = \begin{cases} 1 & \text{for } x = c \\ 0 & \text{for } x \neq c \end{cases} \quad ; \forall x \in \mathbb{R}$$

٢- بالعودة إلى المثال / ٢ / من (٣, ١, ٥) نجد أن قانون توزيع المتغير العشوائي X يُعين على النحو الآتي. من أجل أي حادث B من \mathcal{R} لدينا:

$$P_X(B) = \begin{cases} q = 1 - p & \text{for } 0 \in B \\ p & \text{for } 1 \in B \\ 1 & \text{for } 0 \text{ and } 1 \in B \\ 0 & \text{for } 0 \text{ and } 1 \notin B \end{cases}$$

التي يمكن كتابتها على النحو الآتي أيضًا:

$$P_X(\{x\}) = \begin{cases} q & \text{for } x = 0 \\ p & \text{for } x = 1 \\ 0 & \text{O.W.} \end{cases} ; \forall x \in \mathbb{R}$$

٣- بالعودة إلى المثال /٣/ من (٥, ١, ١, ٣) نجد أن قانون توزيع المتغير العشوائي X يُعَيَّن على النحو الآتي. من أجل أي حدث B من \mathfrak{R} لدينا:

$$P_X(B) = P(X^{-1}(B)) = \sum_{\omega_1, \omega_2=1}^6 \frac{1}{36} \delta_{(\omega_1, \omega_2)}(X^{-1}(B))$$

وهذا يعني أن:

$$P_X = \sum_{\omega_1, \omega_2=1}^6 \frac{1}{36} \delta_{(\omega_1, \omega_2)} \circ X^{-1}$$

أو أن نقدّمه بالشكل الآتي أيضاً. من أجل كل $x \in \mathbb{R}$ لدينا:

$$P_X(\{x\}) = P(X^{-1}(\{x\})) = \sum_{\omega_1, \omega_2=1}^6 \frac{1}{36} \delta_{(\omega_1, \omega_2)}(X^{-1}(\{x\})) = \frac{1}{36} \sum_{\omega_1, \omega_2=1}^6 \mathbf{I}_{X^{-1}(\{x\})}(\omega_1, \omega_2)$$

٤- بالعودة إلى المثال /٤/ من (٥, ١, ١, ٣) نجد أن قانون توزيع المتغير العشوائي X يُعَيَّن على النحو الآتي:

$$P_X(A) = \frac{1}{b-a} \int_{A \cap [a, b]} dx ; \forall A \in \mathfrak{R}$$

٥- ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتمالياً معطى على النحو الآتي:

$$\Omega = [0, \infty) \times [0, \infty)$$

$$\mathcal{A} = \mathbb{R}^2 \cap [0, \infty) \times [0, \infty)$$

$$P(A) := \int_A e^{-x_1} e^{-x_2} dx_1 dx_2 ; \forall A \in \mathfrak{R}$$

وليكن X متغيراً عشوائياً فوق $[\Omega, \mathcal{A}, P]$ معرفاً كما يلي:

$$X((x_1, x_2)) := x_1 + x_2$$


والشكل الجانبي (٥, ٢) يوضح مجموعة قيم المتغير العشوائي X .

والآن لتعيين قانون توزيع X سنأخذ $B \in \mathfrak{R}$ كيفية، فيكون لدينا الآتي:

$$\begin{aligned} P_X(B) &= P(X^{-1}(B)) = \int_{X^{-1}(B)} P(d\omega) = \int P(d\omega) \mathbf{I}_B(X(\omega)) \\ &= \int e^{-(x_1+x_2)} \mathbf{I}_B(x_1+x_2) \lambda(d(x_1, x_2)) = \int e^{-(x_1+x_2)} \mathbf{I}_B(x_1+x_2) dx_1 dx_2 \end{aligned}$$

علماً أن λ هو قياس لوبيغ على \mathbb{R}^2 ، وبما أن الدالة المستكملة قابلة للمكاملة بحسب مفهوم ريمان، فإنه يمكننا أن نعيّن P_X من خلال العلاقة الآتية:

$$P_X(B) = \int e^{-(x_1+x_2)} \mathbf{I}_B(x_1+x_2) dx_1 dx_2$$



(٥, ٢, ٢) دالة التوزيع لمتغير عشوائي Distribution Function of Random Variable

في كثير من الحالات، وخاصة لدى الجوانب التطبيقية والعملية، لا يظهر فيها المتغير العشوائي بشكله الصريح؛ ولذا يستعاض عنه بتقديم ما يُعرف باسم **دالة توزيع** Distribution Function متغير عشوائي (ويطلق عليها البعض اسم **دالة التوزيع التراكمية Cumulative Distribution Function** أيضاً)، وهذه الدالة تساعدنا في حساب احتمالات متعلقة بمتغير عشوائي. إنَّ التعريف الرياضي لهذا المفهوم تقدّمه لنا الفقرة الآتية.

(٥, ٢, ٢, ١) تعريف (دالة توزيع متغير عشوائي)

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، ولنعرّف من أجل هذا المتغير العشوائي دالة حقيقية F_X على \mathbb{R} من خلال العلاقة الآتية:

$$F_X(x) = P(\{\omega \in \Omega; X(\omega) < x\}) \quad ; \forall x \in \mathbb{R} \quad [5,8]$$

عندئذ تُدعى F_X **دالة التوزيع** للمتغير العشوائي X .

(٥, ٢, ٢, ٢) ملاحظات

١- من أجل أي x من \mathbb{R} نجد أن:

$$F_X(x) = P(\{\omega \in \Omega; X(\omega) < x\}) = P(X^{-1}(-\infty, x)) = P_X((-\infty, x))$$

وهذا يعني أن قيمة دالة التوزيع الاحتمالية F_X عند نقطة x من \mathbb{R} ما هي إلا احتمال الحادث $(-\infty, x)$ وفقاً لقانون توزيع المتغير العشوائي X .

٢- كما هو واضح من تعريف دالة التوزيع الاحتمالية F_X فإن مجموعة قيمها هي الفترة $[0, 1]$.

٣- إنَّ تعريف دالة توزيع متغير عشوائي ما هو إلا حالة خاصة من تعريف أكثر شمولية يُعرف باسم **دالة توزيع قياس احتمالي** الذي يُصاغ على النحو الآتي: لنأخذ Q قياساً احتمالياً على الفضاء المقيس $[\mathbb{R}, \mathcal{R}]$ ، ولنعرّف من أجله دالة حقيقية F_Q على \mathbb{R} من خلال العلاقة الآتية:

$$F_Q(x) := Q((-\infty, x)) \quad ; \forall x \in \mathbb{R} \quad [5,9]$$

فعندئذ الدالة F_Q تُدعى **دالة توزيع القياس الاحتمالي** Q ، وهنا يجب الانتباه إلى أنه في الحالة العامة لدينا $Q([a, b]) \neq Q([a, b))$ وذلك من أجل $-\infty < a < b < +\infty$.

الآن لو افترضنا أن X متغير عشوائي فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، وقمنا بأخذ $Q = P_X$ فإنه بحسب الملاحظة السابقة سنحصل على دالة توزيع X أيضاً، وذلك لأنّه من أجل أية قيمة $x \in \mathbb{R}$ لدينا ما يلي:

$$F_{P_X}(x) = P_X((-\infty, x)) = P(X^{-1}(-\infty, x)) = P(X \in (-\infty, x)) = P(X < x) = F_X(x)$$

فيما يلي سنقدّم بعض المبرهنات التي تُظهر لنا بعض خصائص دالة التوزيع الاحتمالية لمتغير عشوائي واستخداماتها، وسنبداها بالمبرهنة الآتية التي تمكّننا من استخدام دالة التوزيع الاحتمالية في حساب احتمالات تتعلق بمتغير عشوائي X .

(٥, ٢, ٢, ٣) مبرهنة

لتكن F_X دالة توزيع متغير عشوائي X معرف فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ من أجل $-\infty < a < b < +\infty$ يكون لدينا العلاقة الآتية محققة:

$$P(a \leq X < b) = F_X(b) - F_X(a) \quad [5,10]$$

البرهان: بما أن $a < b$ فعندئذ سيكون لدينا:

$$\{\omega \in \Omega ; X(\omega) < b\} \supset \{\omega \in \Omega ; X(\omega) < a\}$$

ومن ثم يمكننا أن نكتب الآتي:

$$\begin{aligned} P(a \leq X < b) &= P(\{\omega \in \Omega ; a \leq X(\omega) < b\}) = P(\{\omega \in \Omega ; X(\omega) < b\} \setminus \{\omega \in \Omega ; X(\omega) < a\}) \\ &= P(\{\omega \in \Omega ; X(\omega) < b\}) - P(\{\omega \in \Omega ; X(\omega) < a\}) \\ &= P(X < b) - P(X < a) = F_X(b) - F_X(a) \end{aligned}$$

(٥, ٢, ٣) الخصائص المميزة لدوال التوزيع الاحتمالية على \mathbb{R}

المبرهنة الآتية تقدم لنا أهم الخصائص المميزة لدالة توزيع احتمالية على \mathbb{R} .

(٥, ٢, ٣, ١) مبرهنة

لتكن F_X دالة توزيع متغير عشوائي X معرف فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ يكون للدالة F_X الخصائص الآتية:

e₁ - الدالة F_X غير متناقصة على \mathbb{R} .

e₂ - لدينا:

$$s_1) \lim_{x \rightarrow -\infty} F_X(x) = 0 \quad [5,11-a]$$

$$s_2) \lim_{x \rightarrow +\infty} F_X(x) = 1 \quad [5,11-b]$$

e₃ - الدالة F_X مستمرة من اليسار (على الأقل) عند كل نقطة $x \in \mathbb{R}$.

إن هذه الخاصية الأخيرة تكون موضع اهتمامنا عندما تعاني دالة التوزيع F_X من نقاط انقطاع فقط، وذلك لأنه إذا كانت F_X مستمرة على \mathbb{R} فإنها تكون مستمرة من اليسار واليمين عند كل نقطة من \mathbb{R} .

البرهان: من أجل الفقرة:



e₁ - ليكن لدينا x_1 و x_2 من \mathbb{R} مع $x_2 > x_1$ ، فعندئذ يكون لدينا:

$$\{\omega \in \Omega ; X(\omega) < x_1\} \supset \{\omega \in \Omega ; X(\omega) < x_2\}$$

ومن ثم بحسب خاصية الاطراد للقياس الاحتمالي يمكننا أن نكتب الآتي:

$$F_X(x_2) = P(\{\omega \in \Omega ; X(\omega) < x_2\}) \geq P(\{\omega \in \Omega ; X(\omega) < x_1\}) = F_X(x_1)$$

وهذا يعني أن الدالة F_X غير متناقصة على \mathbb{R} . إن حالة المساواة $F_X(x_2) = F_X(x_1)$ تتحقق عندما تكون الدالة F_X ثابتة على فترة تحوي x_1 و x_2 (انظر الشكلين الآتين).



$e_2 -$ لإثبات صحة النهاية (S_1) سنأخذ متتالية عددية $(x_n)_{n \in \mathbb{N}}$ متناقصة نحو $-\infty$ (أي إن $\lim_{n \rightarrow \infty} x_n = -\infty$)، فعندئذ متتالية الحوادث $(-\infty, x_n)$ سوف تتقارب من الأعلى من الحادث المستحيل \emptyset ، أي إن $\downarrow_{n \rightarrow \infty} (-\infty, x_n) = \emptyset$ ، ومن ثم بحسب خاصية الاستمرار من الأعلى للقياسات يمكننا أن نكتب الآتي:

$$\lim_{x \rightarrow -\infty} F_X(x) = \lim_{n \rightarrow \infty} P_X((-\infty, x_n)) = P_X\left(\lim_{n \rightarrow \infty} (-\infty, x_n)\right) = P_X(\emptyset) = 0$$

وأما لإثبات صحة النهاية (S_2) سنأخذ متتالية عددية $(y_n)_{n \in \mathbb{N}}$ متزايدة نحو $+\infty$ (أي إن $\lim_{n \rightarrow \infty} y_n = +\infty$)، فعندئذ متتالية الحوادث $(-\infty, y_n)$ سوف تتقارب من الأدنى نحو الحادث الأكيد \mathbb{R} ، أي إن $\uparrow_{n \rightarrow \infty} (-\infty, y_n) = \mathbb{R}$ ، ومن ثم بحسب خاصية الاستمرار من الأدنى للقياسات يمكننا أن نكتب الآتي:

$$\lim_{x \rightarrow +\infty} F_X(x) = \lim_{n \rightarrow \infty} P_X((-\infty, x_n)) = P_X\left(\lim_{n \rightarrow \infty} (-\infty, x_n)\right) = P_X(\mathbb{R}) = 1$$

$e_3 -$ لإثبات خاصية الاستمرار من اليسار للدالة F_X عند نقاط الانقطاع سنأخذ $\mathbb{R} \ni x_o$ نقطة ما من نقط انقطاع الدالة F_X ، ولنأخذ متتالية عددية $(y_n)_{n \in \mathbb{N}}$ متزايدة ومتقاربة من x_o ، أي إن $\lim_{n \rightarrow \infty} y_n = x_o$ ، فعندئذ متتالية الحوادث $(-\infty, y_n)$ سوف تتقارب من الأدنى نحو الحادث $(-\infty, x_o)$ ، ولذلك سيكون لدينا $\bigcup_{n=1}^{\infty} (-\infty, y_n) = (-\infty, x_o)$ ، ومن ثم بحسب خاصية الاستمرار من الأدنى للقياسات ينتج لدينا:

$$\begin{aligned} \lim_{n \rightarrow \infty} F_X(y_n) &= \lim_{n \rightarrow \infty} P_X((-\infty, y_n)) = P_X\left(\lim_{n \rightarrow \infty} (-\infty, y_n)\right) \\ &= P_X\left(\bigcup_{n=1}^{\infty} (-\infty, y_n)\right) = P_X((-\infty, x_o)) \\ &= P(X^{-1}((-\infty, x_o))) = P(X < x_o) = F_X(x_o) \end{aligned}$$

وبهذا يتم البرهان.

(٢, ٣, ٢, ٥) ملاحظة

يمكن البرهان (انظر [64]) على أنه لكل دالة حقيقية F معرفة على \mathbb{R} وتتمتع بالخواص e_1, e_2, e_3 يوجد قياس احتمالي وحيد Q على $[\mathbb{R}, \mathfrak{R}]$ بحيث يكون لدينا ما يلي مُحققاً:

$$F_Q(x) = F(x) \quad ; \forall x \in \mathbb{R} \quad [5,12]$$


وهذا يعني أن كل دالة حقيقية F معرفة على \mathbb{R} وتُحقق الخواص e_1, e_2, e_3 هي دالة توزيع احتمالية، بمعنى أنه يوجد متغير عشوائي X بحيث يكون من أجل كل $\mathbb{R} \ni x$ لدينا $F(x) = F_X(x)$ (من أجل ذلك يكفي أن نأخذ $Q = P_X$).

(٣, ٣, ٢, ٥) نتائج

١- مما سبق ينتج لدينا أن الخواص e_1, e_2, e_3 تميز دالة التوزيع الاحتمالية على \mathbb{R} بشكل تام.

٢- إذا عانت دالة التوزيع الاحتمالية F_X من نقطة انقطاع في موضع $\mathbb{R} \ni x_o$ فإنها تقوم بقفزة نحو الأعلى عند هذه النقطة (انظر الشكل (٤, ٥))، وبما أن دوال التوزيع الاحتمالية مستمرة من اليسار عند النقطة x_o فإنه يوضع نقطة مضخمة على الطرف الأيمن لمنحنى الدالة ليدل على قيمتها عند هذه النقطة في حين يوضع رأس سهم على الطرف الأيسر لمنحنى الدالة عند هذه النقطة للدلالة على عدم مساواة قيمة الدالة لهذا الموضع، والشكل الآتي يوضح ذلك، علماً أن $F_X(x_o^+)$ تشير إلى قيمة النهاية من اليمين عند النقطة x_o .

٣- إن مجموعة نقط الانقطاع لدالة توزيع احتمالية F تكون إما منتهية أو قابلة للعد على الأكثر.




الإثبات: بفرض أن x نقطة انقطاع لـ F فإنه يمكننا من أجلها تعريف فترة مفتوحة I_x كما يلي:

$$I_x = (F(x^-), F(x^+))$$

علماً أن $F_X(x^-)$ و $F_X(x^+)$ تشيران على الترتيب إلى قيمة النهاية من اليسار واليمين

للدالة F عند النقطة x ، فإذا كانت x و y نقطتي انقطاع مختلفتين لدالة التوزيع F ، فعندئذ

سيكون لدينا $I_x \cap I_y = \emptyset$ (انظر الشكل الآتي (٥, ٥)) علماً أن الفترة I_y هي الفترة الناتجة عن نقطتي النهاية $F(y^-)$ و $F(y^+)$ أي إن $I_y = (F(y^-), F(y^+))$.



و من جهة أخرى نعلم (من نظرية المجموعات) أن مجموعة كل الفترات المفتوحة في \mathbb{R} تكون منتهية أو قابلة للعد على الأكثر، ومن ثم الفترة $[0, 1]$ (التي تمثل مجموعة قيم الدالة F) ستحتوي على الأكثر عدداً قابلاً للعد من الفترات المفتوحة الناتجة عن نقط الانقطاع لـ F ، وذلك لأن الفترة $[0, 1]$ تحوي كل الفترات المفتوحة الناتجة عن نقط الانقطاع لـ F .

الشكل (٥, ٥)

(٥, ٢, ٣, ٤) ملاحظات

١- إن مجموعة نقط الاستمرار لدالة توزيع احتمالية F هي مجموعة كثيفة في \mathbb{R} دوماً، ومع ذلك فمن الممكن أن تكون مجموعة نقط الانقطاع لدالة التوزيع الاحتمالية F هي مجموعة كثيفة في \mathbb{R} أيضاً، ولتوضيح ذلك سنأخذ متغيراً عشوائياً مجموعة قيمه $X = \{x_n \in \mathbb{Q} ; \forall n \in \mathbb{N}\}$ ، وقانون توزيعه معطى من خلال العلاقة الآتية:

$$P_X(\{x_n\}) = P(X = x_n) = \frac{6}{\pi^2 n^2} ; n \in \mathbb{N}$$

فعندئذ سيكون لدينا:

$$F_X(x) = \sum_{\substack{n=1 \\ x_n < x}}^{\infty} P(X = x_n)$$

فلاحظ أن مجموعة نقط الانقطاع للدالة F_X هي مجموعة الأعداد العادية \mathbb{Q} ، وهي مجموعة كثيفة في \mathbb{R} كما نعلم.

٢- تُعرف بعض المراجع دالة التوزيع لمتغير عشوائي X من خلال العلاقة الآتية:

$$F_X(x) = P(X \leq x) ; \forall x \in \mathbb{R} \quad [5,13]$$

وفي هذه الحالة تصبح دالة التوزيع F_X مستمرة من اليمين (عوضاً عن الاستمرار من اليسار) عند كل نقطة $x \in \mathbb{R}$ ، وأكثر من ذلك ستزداد قيمة هذه الدالة في كل نقطة انقطاع x_0 بمقدار يساوي:


$$\Delta = F_X(x_0^+) - F_X(x_0^-) = P(X \leq x_0) - P(X < x_0)$$

ولتوضيح ذلك لنأخذ تجربة إلقاء حجر نرد متوازن لمرة واحدة فقط، ولنأخذ X تطبيقاً فوق الفضاء الاحتمالي لهذه التجربة العشوائية معروفاً من خلال العلاقة $X(\omega) = \omega$ ، فعندئذ نجد أن X هو متغير عشوائي (تحقق من صحة ذلك) متقطع؛ وذلك لأن مجموعة قيمه

$X = \{1, 2, 3, 4, 5, 6\}$ منتهية، فإذا كانت دالة توزيع هذا المتغير العشوائي معرفةً بالعلاقة $F_X(x) = P(X < x)$ ، فإنه سيكون لدالة توزيع هذا المتغير العشوائي العرض الآتي:

$$F_X(x) = \begin{cases} 0 & \text{for } x \leq 1 \\ \frac{i}{6} & \text{for } i < x \leq i+1 \text{ for } i = 1, 2, 3, 4, 5 \\ 1 & \text{for } x > 6 \end{cases}$$

ولرسمها البياني الشكل الآتي:



الشكل (٦، ٥ أ.)

فيكون لدينا على سبيل المثال ما يلي:

$$F_X(1) = 0 \quad \& \quad F_X(1+\alpha) = \frac{1}{6} \quad ; \quad 0 < \alpha \leq 1$$


$$F_X(3) = \frac{2}{6} \quad \& \quad F_X(3+\alpha) = \frac{3}{6} \quad ; \quad 0 < \alpha \leq 1$$

$$F_X(6) = \frac{5}{6} \quad \& \quad F_X(6+\alpha) = 1 \quad ; \quad \alpha > 0$$

وأما إذا كانت دالة توزيع المتغير العشوائي X معرفةً بالعلاقة $[5, 13]$ ، فعندئذ سيكون لدالة توزيع هذا المتغير العشوائي العرض الآتي:

$$F_X(x) = \begin{cases} 0 & \text{for } x < 1 \\ \frac{i}{6} & \text{for } i \leq x < i+1 \quad ; \quad i = 1, 2, \dots, 5 \\ 1 & \text{for } x \geq 6 \end{cases}$$

وأما رسمها البياني فله الشكل الآتي:



الشكل (٦، ٥ ب.)

ويكون لدينا في هذه الحالة (على سبيل المثال) ما يلي:

$$F_X(1) = \frac{1}{6} \quad \& \quad F_X(1-\alpha) = 0 \quad ; \alpha > 0$$

$$F_X(3) = \frac{3}{6} \quad \& \quad F_X(3-\alpha) = \frac{2}{6} \quad ; 0 < \alpha \leq 1$$

$$F_X(6) = 1 \quad \& \quad F_X(6-\alpha) = \frac{5}{6} \quad ; 0 < \alpha \leq 1$$

(٤, ٢, ٥) مبرهنة (الشرط اللازم والكافي لاستمرار دالة توزيع احتمالية على \mathbb{R})

لتكن F_X دالة توزيع متغير عشوائي X فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ تكون الدالة F_X مستمرة على \mathbb{R} إذا وفقط إذا كان من أجل كل $x \in \mathbb{R}$ لدينا العلاقة الآتية مُحَقَّقة:

$$P(X = x) = 0$$

[5,14]

البرهان: من أجل لزوم الشرط:

لدينا الدالة F_X مستمرة على \mathbb{R} ، ومن ثم بحسب تعريف الاستمرار للدوال يكون من أجل كل $0 < \varepsilon < 1$ يوجد $0 < \delta < 1$ بحيث أنه من أجل $x \in \mathbb{R}$ نقطة استمرار لـ F_X ، ومن أجل كل $y \in \mathbb{R}$ يكون لدينا $|F_X(y) - F_X(x)| < \varepsilon$ مادام $|y - x| < \delta$ ، فلو أخذنا $y > x$ (على سبيل المثال لا الحصر) فإنه بحسب خاصية عدم التناقض لدوال التوزيع الاحتمالية سيكون من أجل $|y - x| < \delta$ الآتي مُحَقَّقًا:

$$|F_X(y) - F_X(x)| = F_X(y) - F_X(x) = P(x \leq X < y)$$

ومن جانب آخر نعلم من خاصية الاطراد للقياس الاحتمالي P أن:

$$P(X = x) \leq P(x \leq X < y)$$

ومن ثم ينتج لدينا $P_X(\{x\}) < \varepsilon$ وذلك لأن:

$$P(X = x) = P_X(\{x\}) \leq P(x \leq X < y) < \varepsilon$$

وذلك بغض النظر عن قيمة $y \in \mathbb{R}$ ، ومنه بحكم إمكانية اختيار العدد ε صغيراً بالقدر الذي نريد يمكننا أن نكتب $P(X = x) = 0$ وبهذا يتم الإثبات.

من أجل كفاية الشرط:

لدينا $P(X = x) = 0$ من أجل كل $x \in \mathbb{R}$ ، فعندئذ لإثبات استمرار الدالة F_X يكفي أن نثبت أنها مستمرة من اليمين عند كل نقطة $x \in \mathbb{R}$ (لأنها مستمرة من اليسار عند كل نقطة $x \in \mathbb{R}$). لذلك لنأخذ $(y_n)_{n \in \mathbb{N}}$ متتالية عددية بحيث تكون $x < y_n$ من أجل كل $n \in \mathbb{N}$ وكذلك $\lim_{n \rightarrow \infty} y_n = x$ ، فعندئذ بحسب مبرهنة في التحليل الرياضي حول الفترات المتداخلة، ومن خصائص دالة التوزيع F_X والقياس الاحتمالي P يمكننا أن نكتب الآتي:

$$\begin{aligned} \lim_{n \rightarrow \infty} F_X(y_n) &= \lim_{n \rightarrow \infty} P_X((-\infty, y_n)) = P_X\left(\lim_{n \rightarrow \infty} (-\infty, y_n)\right) \\ &= P_X((-\infty, x]) = P_X((-\infty, x)) + P_X(\{x\}) = F_X(x) + P_X(\{x\}) \end{aligned}$$

ولكن من الفرض لدينا $P_X(\{x\}) = 0$ من أجل كل $x \in \mathbb{R}$ ، ولذلك يكون لدينا:

$$\lim_{n \rightarrow \infty} F_X(y_n) = F_X(x) \quad ; \forall x \in \mathbb{R}$$

وهذا يعني أن دالة التوزيع F_X مستمرة من اليمين عند كل نقطة $x \in \mathbb{R}$ ، ومن ثم الدالة F_X مستمرة عند كل نقطة $x \in \mathbb{R}$ ، وبهذا يتم البرهان.


(١, ٢, ٤, ٥) أمثلة

١- بالعودة إلى المثال (٣, ١, ١, ٥) حيث لدينا X متغير عشوائي معرف على Ω من خلال العلاقة الآتية:

$$X(\omega) = c \quad ; \quad \forall \omega \in \Omega$$

علماً أن c ثابت عددي، فعندئذ نجد أن دالة توزيع المتغير العشوائي X العرض الآتي:

$$F_X(x) = P(X < x) = \begin{cases} 0 & \text{for } x \leq c \\ 1 & \text{for } x > c \end{cases}$$



الشكل (٥, ٧) الرسم البياني لدالة التوزيع الاحتمالية.


ونذكر هنا مرة أخرى أن الدائرة المغلقة عند نقطة الانقطاع تدل على النهاية من اليسار عند هذه النقطة والمساوية لـ $F_X(c)$ ، بينما يدل رأس السهم عند نقطة الانقطاع إلى قيمة النهاية من اليمين عند هذه النقطة. كذلك نلاحظ أن لهذه الدالة شكل دالة درجية بقفزة واحدة فقط عند c ، ولذا فشكلها البياني هو أبسط شكل بين الأشكال البيانية للدوال الدرجية.

٢- بالعودة إلى المثال /٢/ من (٣, ١, ١, ٥) حيث لدينا X متغيراً عشوائياً معرفاً على Ω من خلال العلاقة الآتية:

$$X(\omega) = \begin{cases} 0 & \text{for } \omega = \omega_2 \\ 1 & \text{for } \omega = \omega_1 \end{cases}$$

فلو افترضنا أن $p := P(X = 1)$ ، فعندئذ نجد أن دالة التوزيع الاحتمالية لهذا المتغير العشوائي لها العرض الآتي:

$$F_X(x) = \begin{cases} 0 & \text{for } x \leq 0 \\ 1 - p = q & \text{for } 0 < x \leq 1 \\ 1 & \text{for } x > 1 \end{cases}$$




الشكل (٥, ٨) الرسم البياني لدالة التوزيع الاحتمالية (لهذه الدالة شكل دالة درجية بقفزتين فقط).

٣- بالعودة إلى المثال /٣/ من (٣, ١, ١, ٥) حيث لدينا X متغير عشوائي معرف على Ω من خلال العلاقة الآتية:

$$X(\omega) = \begin{cases} 0 & \text{for } \omega_1 + \omega_2 < 10 \\ 1 & \text{for } \omega_1 + \omega_2 \geq 10 \end{cases}$$

فنجذ أن دالة التوزيع لهذا المتغير العشوائي لها العرض والشكل الآتين:

$$F_X(x) = P(X < x) = \begin{cases} 0 & \text{for } x \leq 0 \\ \frac{30}{36} & \text{for } 0 < x \leq 1 \\ 1 & \text{for } x > 1 \end{cases}$$



الشكل (٥, ٩) الرسم البياني لدالة التوزيع الاحتمالية.

٤- بالعودة إلى المثال /٤/ من (٥, ١, ١, ٣) حيث المتغير العشوائي X معرف من خلال العلاقة $X(\omega) = \omega$ ، والفضاء الاحتمالي $[\Omega, \mathcal{A}, P]$ معطى كما يلي:

$$\Omega = [a, b] \quad \& \quad \mathcal{A} = \mathbb{R} \cap [a, b] \quad \& \quad P(A) = \frac{1}{b-a} \int_A dx$$

ف نجد بحسابات بسيطة أن لدالة توزيع هذا المتغير العشوائي العرض الآتي:



الشكل (٥, ١٠) الرسم البياني لدالة التوزيع الاحتمالية (دالة مستمرة على \mathbb{R}).

وهنا نلاحظ أن دالة التوزيع الاحتمالية F_X مستمرة على \mathbb{R} ، في حين أن دوال التوزيع الاحتمالية في الأمثلة الثلاث السابقة كانت دوال درجية (هذه الملاحظة توحى لنا إلى وجود تصنيفات للمتغيرات العشوائية).

٥- بالعودة إلى المثال /٥/ من (٥, ١, ١, ٣) حيث المتغير العشوائي X معرف على Ω من خلال العلاقة الآتية:

$$X((x_1, x_2)) := x_1 + x_2$$

ف نجد من أجل كل $0 < x$ أن:

$$\begin{aligned} F_X(x) &= P\left(\{(x_1, x_2) \in \Omega \mid X((x_1, x_2)) < x\}\right) \\ &= \iint_{x_1, x_2 \geq 0; x_1 + x_2 < x} e^{-x_1} e^{-x_2} dx_1 dx_2 = \int_{x_1=0}^x \int_{x_2=0}^{x-x_1} e^{-x_1} e^{-x_2} dx_1 dx_2 \end{aligned}$$

وبحساب التكامل الذي في الطرف الأيمن من العلاقة الأخيرة نجد:

$$F_X(x) = 1 - \frac{x+1}{e^x}$$

وأما من أجل كل $0 \geq x$ فإننا سنضع $F_X(x) = 0$ (قدّم تبريراً لهذا الافتراض)، وبذلك يكون لدالة توزيع X العرض الآتي:



الشكل (٥, ١١) الرسم البياني لدالة التوزيع الاحتمالية (دالة مستمرة على \mathbb{R}).

٦- لنقم بإلقاء قطعة نقود (ليست بالضرورة أن تكون متوازنة) لمرة واحدة فقط، فإذا حصلنا على صورة فإننا نلق قضيياً على المستوى الأفقي بشكل عشوائي، فيصنع زاوية α مع الشمال الجغرافي، وأما إذا حصلنا على شعار فإننا ننهي التجربة. عندئذ سيكون لمجموعة نتائج هذه التجربة العشوائية العرض الآتي:


$$\Omega = \{T\} + \{(H, \alpha) ; \alpha \in [0, \pi)\}$$

ولنعرف متغيراً عشوائياً X فوق الفضاء الاحتمالي لهذه التجربة من خلال العلاقة الآتية:

$$X(\omega) := \begin{cases} -1 & \text{for } \omega = T \\ \alpha & \text{for } \omega = (H, \alpha) \end{cases}$$

ف نجد أن مجموعة قيم هذا المتغير العشوائي هي $X = \{-1\} \cup [0, \pi)$ ، ومن ناحية أخرى بفرض أن احتمال الحصول على الشعار يساوي $0 < p < 1$ ، فإنه سيكون لدالة التوزيع الاحتمالية لهذا المتغير العشوائي العرض الآتي:

$$F_X(x) = \begin{cases} 0 & \text{for } x \leq -1 \\ p & \text{for } -1 < x \leq 0 \\ p + \frac{1-p}{\pi} x & \text{for } 0 < x \leq \pi \\ 1 & \text{for } x > \pi \end{cases}$$



الشكل (٥، ١٢) الرسم البياني لدالة التوزيع الاحتمالية (دالة ليست مستمرة على \mathbb{R}).

فلاحظ من الرسم البياني للدالة F_X أنها مستمرة على المجموعة $\mathbb{R} \setminus \{-1\}$ حيث تعاني من نقطة انقطاع عند النقطة $x = -1$.

(٥، ٣) تصنيف المتغيرات العشوائية

Classification of Random Variables

لو أمعنا النظر في الأمثلة السابقة (١، ٤، ٢، ٥) فإننا نلاحظ أن هناك متغيرات عشوائية دوال توزيعها درجية كما في الأمثلة ١ / ٢ و ٣ /، وأخرى دوال توزيعها مستمرة كما في المثالين ٤ / ٥ و ٦ /، ونوع ثالث دوال توزيعها ليست درجية وليست مستمرة كما في المثال ٦ /، وبناءً على ذلك يمكننا تصنيف المتغيرات العشوائية في ثلاثة أصناف رئيسية هي:

١- متغيرات عشوائية دوال توزيعها الاحتمالية مستمرة على \mathbb{R} ، وهذا النوع يُعرف باسم **متغيرات عشوائية مستمرة** Continuous Random Variables. إن مجموعة قيم هذا النوع من المتغيرات العشوائية تكون غير قابلة للعدّ دوماً.

٢- متغيرات عشوائية دوال توزيعها ليست مستمرة على \mathbb{R} ، وهنا نميز بين نوعين من هذه المتغيرات العشوائية أيضاً هما:

أ- متغيرات عشوائية دوال توزيعها ليست مستمرة على كامل \mathbb{R} (تعاني من نقطة انقطاع واحدة على الأقل)، ولكنها ليست دوال درجية أيضاً، فعندئذ يُقال عن هذا النوع من المتغيرات العشوائية إنها **متغيرات عشوائية غير مستمرة** Uncontinuous Random Variables، ومن الأمثلة على هذا النوع المثال ٦ / من الفقرة (١، ٤، ٢، ٥) حيث عرض لنا متغيراً عشوائياً دالة توزيعه F_X تعاني من انقطاع عند النقطة $x = -1$ ورسمها البياني بين أنها ليست دالة درجية. إن مجموعة قيم هذا النوع من المتغيرات العشوائية ستكون مجموعات غير قابلة للعدّ دوماً. (في كتابنا هذا لن نتطرق إلى دراسة هذا النوع من المتغيرات العشوائية).

ب- متغيرات عشوائية دوال توزيعها ليست مستمرة على كامل \mathbb{R} ، ولكنها دوال درجية كما في الأمثلة ١ / ٢ و ٣ /

من (١, ٢, ٤, ٥). إنَّ هذا النوع من المتغيرات العشوائية يُعرف باسم **المتغيرات العشوائية المتقطعة** Discrete Random Variables. إنَّ مجموعة القيم لهذا النوع من المتغيرات العشوائية تكون قابلة للعدِّ على الأكثر حتمًا.

إذاً يمكن تصنيف المتغيرات العشوائية في ثلاثة أنواع رئيسة وفقاً لشكل دالة التوزيع، ولكن بما أنَّ دوال التوزيع تأتي كمرحلة لاحقة لتعيين المتغير العشوائي فإنَّ ذلك يوجب علينا تقديم التصنيف انطلاقاً من الخصائص التي يتمتع بها المتغير العشوائي نفسه بحيث تؤل دوال توزيعها إلى أحد الأصناف الثلاثة السابقة.

نقدّم فيما يأتي تعاريف لهذه الأصناف الثلاثة، وسنركّز (في دراستنا لهذا الكتاب) على المتغيرات العشوائية المتقطعة والمستمرة فقط.

(١, ٣, ٥) المتغيرات العشوائية المتقطعة Discrete Random Variables

نبدأ دراسة المتغيرات العشوائية المتقطعة بالتعريف الآتي.

(١, ٣, ٥) تعريف (المتغير العشوائي المتقطع)

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فإذا كانت مجموعة قيم X منتهية أو غير منتهية ولكنها قابلة للعدِّ، فعندئذ يُقال عن هذا المتغير العشوائي إنَّه **متقطع** Discrete.

(٢, ٣, ٥) ملاحظات

١- يمكن عرض المتغير العشوائي المتقطع على شكل دالة درجية، وذلك لأنَّه لو افترضنا $\{x_i ; i \in I\}$ هي مجموعة قيم متغير عشوائي متقطع X حيث لدينا مجموعة الأدلة I إما أن تكون منتهية أو غير منتهية ولكنها قابلة للعدِّ، وقمنا بأخذ حوادث Z_i لها العرض الآتي:

$$Z_i = \{\omega \in \Omega ; X(\omega) = x_i\} \quad ; \forall i \in I$$

فإنَّنا نجد من أجل أية قيمة $i \in I$ أنَّ $Z_i \in \mathcal{A}$ ، وكذلك $Z_i = X^{-1}(\{x_i\})$ ، وأكثر من ذلك نلاحظ أنَّ أسرة الحوادث $\mathcal{Z} = \{Z_i ; i \in I\}$ تشكّل تجزئة للحدث الأكيد Ω ، ومن ثمَّ يمكن كتابة المتغير العشوائي المتقطع X على النحو الآتي:

$$X(\omega) = \sum_{i \in I} x_i \cdot \mathbf{I}_{Z_i}(\omega) \quad ; \forall \omega \in \Omega \quad [5,15-a]$$

وهذا يعني أنَّ X نموذج دالة درجية.

٢- إذا كانت مجموعة الأدلة I منتهية، فعندئذ يمكننا أن نكتب $X = \{x_i ; i \in \mathbb{N}_n\}$ مع n قيمة صحيحة مثبتة، ومن ثمَّ يصبح لصيغة المتغير العشوائي X العرض الآتي:

$$X = \sum_{k=1}^n x_k \cdot \mathbf{I}_{Z_k} \quad ; Z_1, Z_2, \dots, Z_n \in \mathcal{A} \quad [5,15-b]$$

وفي هذه الحالة يُقال عن المتغير العشوائي X إنَّه **بسيط** Simple Random Variable، فعلى سبيل المثال لو أخذنا تجربة إلقاء حجر نرد متوازن لمرة واحدة، وبفرض أنَّ X متغير عشوائي فوق الفضاء الاحتمالي لهذه التجربة معرّفاً من خلال العلاقة $X(\omega) = \omega$ ، فعندئذ يكون لهذا المتغير العشوائي العرض الآتي:

$$X(\omega) = \sum_{k=1}^6 k \cdot \mathbf{I}_{\{k\}}(\omega) \quad ; \omega = 1, 2, 3, 4, 5, 6$$

ولذلك فإنَّ هذا المتغير العشوائي بسيط.

٣- في حالة المتغيرات العشوائية المتقطعة يكون القياس P_X معيَّناً وبشكل وحيد من خلال العلاقة الآتية:

$$P_X(\{x_i\}) = P(X = x_i) \quad ; i \in I \quad [5,16]$$

وذلك لأنه من أجل أية قيمة $I \ni i$ لدينا:

$$P_X(\{x_i\}) = P(X^{-1}(\{x_i\})) = P(Z_i) = P(\{\omega \in \Omega ; X(\omega) = x_i\}) = P(X = x_i)$$

ويسمى المقدار $P(X = x_i)$ **الكتلة الاحتمالية** Probability Mass للمتغير العشوائي X ، ويرمز لها عادةً بـ p_i من أجل أية قيمة $I \ni i$ (كما قمنا باستخدامه سابقاً)، وفي بعض المراجع يُرمز لها بـ $f_X(x_i)$ ويدعونها **دالة الكتلة الاحتمالية** Probability Mass Function، أي إنه يكتب:

$$p_i = P(X = x_i) = f_X(x_i) \quad ; i \in I$$

لاحظ هنا أنه يجب أن يكون $\sum_{i \in I} p_i = 1$.

(٥, ٣, ٢, ٣) أمثلة

١- بالرجوع إلى الأمثلة ١ / و ٢ و ٣ / من الفقرة (٥, ١, ١, ٣) نجد أنها متغيرات عشوائية متقطعة بمجموعة قيم منتهية، وكذلك الأمر بالنسبة إلى الدالة المميزة I_A عندما يكون A حادثاً.

٢- بالرجوع إلى المثال ١ / المقدم في الملاحظة (٥, ٢, ٣, ٤) نجد أن X متغير عشوائي متقطع بمجموعة قيم غير منتهية ولكنها قابلة للعد.

٣- ليكن X متغيراً عشوائياً فوق فضاء احتمالي ما $[\Omega, \mathcal{A}, P]$ بحيث يمكن له أن يأخذ أية قيمة صحيحة موجبة، ومُعرف من خلال العلاقة الآتية:

$$P(X = n) = \frac{1}{n(n+1)} \quad ; n \in \mathbb{N}$$

فنجد أن:

$$\sum_{i \in I} p_i = \sum_{n=1}^{\infty} P(X = n) = \sum_{n=1}^{\infty} \frac{1}{n(n+1)} = 1$$

وهنا نلاحظ أن مجموعة قيم المتغير العشوائي هي $X = \mathbb{N}$ ، وهي مجموعة غير منتهية ولكنها قابلة للعد. إذاً فهو متغير عشوائي متقطع.

(٥, ٣, ١, ٤) التمثيل الجدولي والبياني للمتغيرات العشوائية المتقطعة **Tabular and graphic Representation of D.R.V.**

إذا كان X متغيراً عشوائياً متقطعاً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ بمجموعة قيم $X = \{x_i ; i \in I\}$ فعندئذ من أجل أية قيمة $I \ni i$ يمكننا أن نكتب الآتي:

$$P_X(\{x_i\}) = P(X^{-1}(\{x_i\})) = P(X = x_i) = p_i$$

والتي تمثل قيمة الكتلية الاحتمالية للمتغير العشوائي X عند القيمة x_i ، وفي الحالة الخاصة عندما تكون مجموعة قيم متغير عشوائي متقطع X منتهية (أي إنه متغير عشوائي بسيط)، فإنه انطلاقاً من معرفة القيم x_i و $P(X = x_i)$ يمكننا تقديم المتغير العشوائي البسيط X (ولو نظرياً على الأقل) وفق طرائق أخرى منها على سبيل المثال:

١- التمثيل الجدولي

بفرض أن X متغير عشوائي بسيط مجموعة قيمه $X = \{x_i ; i \in \mathbb{N}_n\}$ مع $\mathbb{N} \ni n$ مثبت، فعندئذ يمكن تمثيل هذا المتغير العشوائي جدولياً من خلال بناء جدول بصفين يدون في صفه العلوي قيم X وأما في صفه السفلي تدون الاحتمالات الفردية المقابلة

لتلك القيم على النحو المقدم في الجدول الآتي:


الجدول (٥, ١)

i	1	2	n	sum
x_i قيم X	x_1	x_2	x_n	...
$p_i = P(X = x_i)$	p_1	p_2	p_n	1

ويعرف هذا الجدول باسم **جدول توزيع المتغير العشوائي X** أيضاً، وهذه التسمية خاصة بالمتغيرات العشوائية المتقطعة فقط.

٢- التمثيل البياني

بفرض أن X متغير عشوائي بسيط مجموعة قيمه $X = \{x_i ; i \in N_n\}$ مع $N \ni n$ مثبت، فعندئذ يمكن تمثيل هذا المتغير العشوائي بيانياً من خلال رسم محورين إحداثيين متعامدين، ومن ثم رسم عمود بارتفاع يساوي p_i (يدعى قيمة قفزة للمتغير العشوائي) فوق القيمة x_i (وتدعى موضع قفزة للمتغير العشوائي) من أجل أية قيمة $N_n \ni i$ ، ويوضع أحياناً في نهاية كل عمود دائرة صغيرة مصممة (وكأنها وزن) كتعبير عن موضع الكتلة الاحتمالية للمتغير العشوائي عند موضع القفزة، وأما ارتفاع العمود (وهو الأهم في الرسم) فإنه يعبر عن قيمة الكتلة الاحتمالية للمتغير العشوائي X عند موضع القفزة. هكذا يمكن للمتغير العشوائي X أن يمثل بيانياً من خلال الشكل الجانبي.



الشكل (٥, ١٣)

(٥, ٣, ١, ٥) ملاحظات

- ١- في الأشكال القادمة الممثلة للمتغيرات العشوائية المتقطعة سوف نتجاوز عن رسم الدوائر الصغيرة المصممة في نهايات الأعمدة؛ وذلك لأن المهم في هذه العروض هو ارتفاعات الأعمدة عند مواضع القفزات.
 - ٢- يلاحظ عدم جدوى تقديم المتغيرات العشوائية البسيطة بالطريقة الجدولية أو البيانية عندما تكون مجموعة قيمها كبيرة جداً، وأما إذا كانت القيم التي تأخذها هذه المتغيرات العشوائية قليلة فإن هاتين الطريقتين تعطيان عروضاً مقبولة.
- المبرهنة الآتية تقدم لنا صيغة دالة التوزيع لمتغير عشوائي متقطع.

(٥, ٣, ١, ٦) مبرهنة

ليكن X متغيراً عشوائياً متقطعاً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ بمجموعة قيم $X = \{x_i ; i \in I\}$ ، فعندئذ من أجل كل $x \in \mathbb{R}$ يكون لدالة توزيع X العرض الآتي:

$$F_X(x) = \sum_{i \in I; x_i < x} P(X = x_i) \quad [5,17]$$

البرهان: ليكن $x \in \mathbb{R}$ ولنفرض أن S هي مجموعة الأدلة لقيم X التي أصغر من x ، فعندئذ يكون $x = \max\{x_i ; i \in S\}$ ، ومن ثم الاثبات يتم على النحو الآتي:

$$F_X(x) = P(X < x) = P(\{\omega \in \Omega ; X(\omega) < x_1\} \cup \{\omega \in \Omega ; X(\omega) < x_2\} \cup \dots \cup \{\omega \in \Omega ; X(\omega) < x_{|S|}\})$$

$$= P(X \in \sum_{i \in S} \{x_i\}) = \sum_{i \in S} P(X = x_i) = \sum_{i \in I; x_i < x} P(X = x_i)$$

بهذا يتم البرهان.

(٥, ٣, ١, ٧) ملاحظات

- ١- تجدر الإشارة هنا إلى أن التوزيعات الاحتمالية الناتجة عن متغيرات عشوائية متقطعة تدعى **توزيعات متقطعة**.
- ٢- من العلاقة السابقة [5,17] يلاحظ أن الرسم البياني لدوال التوزيع الاحتمالية للمتغيرات العشوائية المتقطعة هي دوال **درجية** دوماً (وقد لاحظنا ذلك في أمثلة سابقة).

(٥, ٣, ١, ٨) أمثلة

١- ليكن لدينا X متغيراً عشوائياً مقدماً جدولياً من خلال الجدول الآتي:

الجدول (٥, ٢)


i	1	2	3	4	5	6	sum
x_i قيم X	0	1	2	3	4	5	...
$P(X = x_i)$	0.031	0.156	0.313	0.313	0.156	0.031	1

فعندئذ نجد أن هذا المتغير العشوائي متقطع بسيط وتميزه العلاقات الآتية:

$$P(X = 0) = 0.031 \quad \& \quad P(X = 1) = 0.156 \quad \& \quad P(X = 2) = 0.313$$

$$P(X = 3) = 0.313 \quad \& \quad P(X = 4) = 0.156 \quad \& \quad P(X = 5) = 0.031$$

ولتمثيله البياني الشكل الآتي:




الشكل (٥, ١٤)

وآما لتعيين دالة توزيعه الاحتمالية فلدينا من أجل كل $x \in \mathbb{R}$ ما يلي:

$$F_X(x) = \sum_{k=0; k < x}^5 P(X = k)$$


ومنه يكون لدينا:

$$F_X(x) = \begin{cases} 0 & \text{for } x \leq 0 \\ 0.031 & \text{for } 0 < x \leq 1 \\ 0.187 & \text{for } 1 < x \leq 2 \\ 0.500 & \text{for } 2 < x \leq 3 \\ 0.813 & \text{for } 3 < x \leq 4 \\ 0.969 & \text{for } 4 < x \leq 5 \\ 1 & \text{for } x > 5 \end{cases}$$



الشكل (٥, ١٤) ب) الرسم البياني لدالة التوزيع الاحتمالية.

٢- ليكن لدينا X متغيراً عشوائياً مقدّماً بيانياً من خلال الشكل الآتي:



الشكل (١٥, ٥).

ف عندئذ نجد لتمثيله الجدولي العرض الجدولي الآتي:

الجدول (٣, ٥)

i	1	2	3	4	5	sum
x_i قيم X	0	1	2	3	4	...
$P(X = x_i)$	0.141	0.355	0.331	0.126	0.047	1

ومن ثمّ العلاقات التي تميّز هذا المتغير العشوائي المتقطع البسيط هي:


$$P(X = 0) = 0.141 \quad \& \quad P(X = 1) = 0.355$$
$$P(X = 2) = 0.126 \quad \& \quad P(X = 3) = 0.126$$
$$P(X = 4) = 0.047$$

وبحسابات بسيطة نجد العلاقة الآتية من أجل دالة التوزيع الاحتمالية لهذا المتغير العشوائي:

$$F_X(x) = 0.141 \, I_{(0,1]}(x) + 0.496 \, I_{(1,2]}(x) + 0.827 \, I_{(2,3]}(x) + 0.953 \, I_{(3,4]}(x) + I_{(4,+\infty)}(x)$$

وأما الشكل البياني لهذه الدالة الدرجية فيترك للقارئ (يشابه الشكل (١٤, ٥ ب)).

٣- ليكن لدينا X متغيراً عشوائياً معطى من خلال العرض البياني لدالة توزيعه الاحتمالية التي لها الشكل الآتي:



الشكل (١٦, ٥ أ)

ف نجد أنّ العرض التحليلي لدالة توزيع هذا المتغير العشوائي هو:


$$F_X(x) = \begin{cases} 0 & \text{for } x \leq 0 \\ 0.25 & \text{for } 0 < x \leq 1 \\ 0.50 & \text{for } 1 < x \leq 2 \\ 0.70 & \text{for } 2 < x \leq 3 \\ 0.86 & \text{for } 3 < x \leq 4 \\ 0.96 & \text{for } 4 < x \leq 5 \\ 1 & \text{for } x > 5 \end{cases}$$

ومن ثم يكون للعلاقات التي تميز هذا المتغير العشوائي العروض الآتية:

$$P(X=0)=0.25 \quad \& \quad P(X=1)=0.50-0.25=0.25 \quad \& \quad P(X=2)=0.70-0.50=0.20$$

$$P(X=3)=0.86-0.70=0.16 \quad \& \quad P(X=4)=0.96-0.86=0.10 \quad \& \quad P(X=5)=1-0.96=0.04$$

وكذلك يصبح لهذا المتغير العشوائي التمثيل البياني والجدولي على النحو الآتي:



٤- لتكن لدينا الدالة الآتية:

$$f(x) = c(x^2 + 2) \quad ; x = 0, 1, 2, 3, 4$$

ولنقم بتعيين قيمة الثابت c بحيث تصبح هذه الدالة هي دالة احتمالية لمتغير عشوائي متقطع X .

من أجل ذلك نعلم أن $\sum_{i \in I} P(X=x_i) = 1$ ، ولذلك حتى تصبح الدالة $f(x)$ هي دالة احتمالية لمتغير عشوائي متقطع X

يجب أن يكون $\sum_{x=0}^4 f(x) = 1$ (أي الدالة $f(x)$ أخذت دور $P(X=x_i)$)، ومنه يكون لدينا:

$$1 = \sum_{x=0}^4 f(x) = \sum_{x=0}^4 c(x^2 + 2) = c(0^2 + 2) + c(1^2 + 2) + c(2^2 + 2) + c(3^2 + 2) + c(4^2 + 2)$$

$$= 2c + 3c + 6c + 11c + 18c = 40c$$

وهكذا نجد أن $c = \frac{1}{40}$ ، ومن ثم يكون للدالة الكتلية للمتغير العشوائي X العرض الآتي:

$$P(X=x) = \frac{x^2 + 2}{40} \quad ; x = 0, 1, 2, 3, 4$$

والتي نجد منها:


$$P(X=0)=0.050 \quad \& \quad P(X=1)=0.075 \quad \& \quad P(X=2)=0.150$$

$$P(X=3)=0.275 \quad \& \quad P(X=4)=0.450$$

وكذلك يصبح هذا المتغير العشوائي التمثيل الجدولي الآتي:

الجدول (٥, ٥)

i	1	2	3	4	5	sum
x_i قيم X	0	1	2	3	4	...
$P(X = x_i)$	0.050	0.075	0.150	0.275	0.450	1

الشكل (٥, ١٧). التمثيل لبياني لـ X .

وبحسابات بسيطة نجد أن لدالة التوزيع الاحتمالية لهذا المتغير العشوائي العرض التحليلي الآتي:

$$F_X(x) = 0.05 \mathbf{I}_{(0,1]}(x) + 0.125 \mathbf{I}_{(1,2]}(x) + 0.275 \mathbf{I}_{(2,3]}(x) + 0.55 \mathbf{I}_{(3,4]}(x) + \mathbf{I}_{(4,+\infty)}(x)$$

الخلاصة: نلاحظ أنه من أجل متغير عشوائي متقطع بسيط وبقيم قليلة العدد يمكننا استخدام أي من التمثيلات التي ذكرناها سابقاً لاستنتاج بقية التمثيلات الأخرى لهذا المتغير العشوائي.

نكتفي بهذا القدر من المعلومات حول المتغيرات العشوائية المتقطعة حيث سنعود إليها مرة أخرى في فقرات وفصول قادمة، وننتقل فيما يلي إلى النوع الثاني من المتغيرات العشوائية.

(٥, ٣, ٢) المتغيرات العشوائية المستمرة Continuous Random Variables

لقد ذكرنا سابقاً أن المتغيرات العشوائية المستمرة تتميز بدوال توزيع احتمالية مستمرة على \mathbb{R} ، ولكن التعريف الدقيق لهذا النوع من المتغيرات العشوائية يقدمه التعريف الآتي.

(٥, ٣, ٢, ١) تعريف (المتغير العشوائي المستمر)

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فإذا وجدت دالة حقيقية f غير سالبة معرفة وقابلة للمكاملة على \mathbb{R}

وتحقق العلاقة $\int_{-\infty}^{+\infty} f(x) dx = 1$ ، فعندئذ يُقال عن X إنه مستمر Continuous، وأما f فإنها تُدعى دالة الكثافة الاحتمالية لـ X .

(٥, ٣, ٢, ٢) ملاحظات

١- بناء على التعريف السابق نلاحظ أن المتغيرات العشوائية المستمرة تكون معينة (أو مُيَّزَة) بوساطة دوال كثافتها الاحتمالية.

٢- إن دالة الكثافة الاحتمالية f المذكورة في التعريف السابق هي في الواقع دالة الكثافة لـ رادون-نيكوديم Radon Nikodym Density Function من القياس P_X بالنسبة إلى قياس لوبيغ λ . إن اسم هذه الدالة يعود إلى الرياضياتي النمساوي رادون Johann Karl August Radon (1887–1956) والرياضياتي البولوني نيكوديم Otto Marcin Nikodym (1887–1974) (للاطلاع على بعض المفاهيم الواردة في هذه الفقرة ارجع إلى الملحق B)، ولتوضيح ذلك لنفترض أنه لدينا X متغير عشوائي فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ وأن قانون توزيعه P_X مستمر مطلقاً بالنسبة إلى قياس لوبيغ λ (علماً أن λ هو قياس من نوع σ -منته على الفضاء المقيس $[\mathbb{R}, \mathcal{R}]$) ويعبر عن ذلك بالرمز $\lambda \ll P_X$ ، فعندئذ الدالة f تنتج من تفاضل رادون-نيكوديم للقياس P_X بالنسبة إلى قياس لوبيغ λ ، أي إن $\frac{dP_X}{d\lambda} = f$ ، وهي دالة غير سالبة وقيوسة بالنسبة إلى \mathcal{R} و $\mathcal{R} \cap [0, \infty)$ ، ويُقال في هذه الحالة إن المتغير العشوائي X مستمر مطلقاً Absolutely Continuous. من جهة أخرى، وبما أن لكل متغير عشوائي X قانون توزيع خاص به P_X فإن كثافة رادون-نيكوديم الناتجة عن هذا التفاضل ستكون خاصة بالمتغير العشوائي X ، ولذلك يُرمز لها بـ f_X ، أي إنه يكتب:

$$\frac{d P_X}{d \lambda} = f_X \quad [5,18]$$

ومن ثم يكون لدينا:

$$P_X(B) = \int_B f_X(x) \lambda(dx) \quad ; \forall B \in \mathcal{R} \quad [5,19]$$

أي إن f_X يجب أن تكون قابلة للمكاملة بحسب مفهوم لوبيغ، وفي حال كانت الدالة f_X قابلة للمكاملة بحسب مفهوم ريمان فإن العلاقة [5,19] يكتب على سبيل التبسيط والاختصار كما يلي:

$$P_X(B) = \int_B f_X(x) dx \quad ; B \in \mathcal{R} \quad [5,20]$$

وبما أن P_X قياس احتمالي على $[\mathcal{R}, \mathcal{R}]$ فإن العلاقة الآتية ستكون محققة دوماً:

$$P_X(\mathcal{R}) = \int_{\mathcal{R}} f_X(x) dx = 1 \quad [5,21]$$

علماً أننا في دراستنا المقبلة لن نتعامل إلا مع دوال كثافة قابلة للمكاملة بحسب مفهوم ريمان.

٣- في الحقيقة يمكن تبين (انظر [64]) أنه لكل دالة حقيقية f معرفة على \mathcal{R} غير سالبة وقيوسة بالنسبة إلى \mathcal{R} و $\mathcal{R} \cap [0, \infty)$ ، وكمولة (قابلة للمكاملة Integrable) بالنسبة إلى قياس لوبيغ λ ، وتحقق العلاقة [5,21] يوجد قياس احتمالي وحيد Q على $[\mathcal{R}, \mathcal{R}]$ بحيث تكون f هي كثافة رادون-نيكوديم من Q بالنسبة إلى قياس لوبيغ λ .

٤- يمكن تعريف المتغير العشوائي المستمر (التعريف التقليدي) على النحو الآتي أيضاً:

يكون متغير عشوائي X فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ مستمراً إذا وجدت من أجله دالة حقيقية غير سالبة f_X معرفة وكمولة على \mathcal{R} ، وبحيث إنه من أجل أي $a, b \in \mathcal{R}$ مع $b \geq a$ تكون العلاقة الآتية محققة:

$$P(a \leq X \leq b) = \int_a^b f_X(x) dx \quad [5,22]$$

ومن هذا التعريف للمتغير العشوائي المستمر، وبحسب مفهوم ريمان لتكامل دالة نلاحظ أن احتمال أن يأخذ متغير عشوائي X قيمة واقعة في فترة $[a, b]$ يساوي للمساحة المحصورة بالمحور Ox والمنحنى الدالة f_X والمستقيمين $x=a$ و $x=b$ (انظر الشكل (٥, ١٨)). حيث يلاحظ أنه عندما تسعى b إلى a فإن المساحة المظللة التي تعبّر عن الاحتمال $P(a \leq X \leq b)$ تصغر أكثر فأكثر حتى إذا أصبحت $b=a$ فإنه يصبح لدينا $P(X=a)=0$ ، وبما أن a قيمة كيفية من \mathcal{R} فإن سيكون لدينا:

$$P(X=a)=0 \quad ; \forall a \in \mathcal{R}$$

ومن ثم نحصل على النتيجة المهمة الآتية.


(٥, ٣, ٢, ٣) نتيجة

من أجل متغير عشوائي مستمر X تكون العلاقات الآتية محققة دوماً:

$$P(a \leq X \leq b) = P(a < X \leq b) = P(a \leq X < b) = P(a < X < b)$$

توضيح آخر لهذه النتيجة تجدها في المثال القادم / ٢ / من (٥, ٣, ٢, ٧).

المبرهنة الآتية تعطينا صيغة دالة التوزيع لمتغير عشوائي مستمر.



الشكل (٥, ١٨)

(٥, ٣, ٢, ٤) مبرهنة

ليكن X متغيراً عشوائياً مستمراً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ بدالة كثافة احتمالية f_X ، فعندئذ من أجل كل $x \in \mathbb{R}$ يكون لدالة توزيع X العرض الآتي:

$$F_X(x) = \int_{-\infty}^x f_X(t) dt \quad ; \forall x \in \mathbb{R} \quad [5,23]$$

البرهان: لتكن $x \in \mathbb{R}$ قيمة كيفية، فعندئذ من تعريف وخواص دالة التوزيع الاحتمالية لمتغير عشوائي، واستخدام العلاقة [5,23] يمكننا أن نكتب الآتي:

$$\begin{aligned} F_X(x) &= P(X < x) = P(X < x) - \lim_{a \rightarrow -\infty} P(X < a) \\ &= \lim_{a \rightarrow -\infty} P(a \leq X < x) = \lim_{a \rightarrow -\infty} P(a \leq X \leq x) = \lim_{a \rightarrow -\infty} \int_a^x f_X(t) dt = \int_{-\infty}^x f_X(t) dt \end{aligned}$$

وبهذا يتم البرهان.

المبرهنة الآتية التي سنقدمها دون برهان (ذلك أن برهانها يُقدّم في مراحل متقدمة من نظرية الاحتمالات) توضّح لنا الشروط الواجب توفرها في دالة حقيقية f حتى تصبح دالة كثافة احتمالية لمتغير عشوائي.

(٥, ٣, ٢, ٥) مبرهنة

لتكن f دالة حقيقية غير سالبة معرفة وكمولة على \mathbb{R} ومُحقّقة للعلاقة $\int_{-\infty}^{\infty} f(x) dx = 1$ ، فعندئذ يوجد متغير عشوائي X بحيث إنّه من أجل كل $x \in \mathbb{R}$ يكون لدينا $f(x) = f_X(x)$.

(٥, ٣, ٢, ٦) نتائج

١- من المبرهنة السابقة وخواص دالة توزيع متغير عشوائي نستنتج أن:

$$\int_{-\infty}^{\infty} f_X(t) dt = 1 \quad [5,24]$$

وذلك لأنّه لدينا من خصائص دالة التوزيع الاحتمالية $\lim_{x \rightarrow \infty} F_X(x) = 1$ ، ومن ثمّ يمكننا أن نكتب الآتي:

$$\lim_{x \rightarrow \infty} F_X(x) = \lim_{x \rightarrow \infty} \int_{-\infty}^x f_X(t) dt = \int_{-\infty}^{\infty} f_X(t) dt = 1$$

٢- ليكن X متغيراً عشوائياً مستمراً بدالة كثافة احتمالية f_X مستمرة في نقطة $x \in \mathbb{R}$ ، فعندئذ (بحسب مبرهنة في حساب التفاضل) تكون دالة توزيعه الاحتمالية F_X قابلة للمفاضلة في هذه النقطة x ، ولدينا:

$$\frac{d F_X(x)}{dx} = f_X(x) \quad [5,25]$$

ومن ثمّ دالة توزيع متغير عشوائي مستمر X تكون مستمرة على \mathbb{R} ؛ وذلك لأنّها بمثابة الدالة الأصلية لدالة حقيقية f_X كمولة على \mathbb{R} (أي لـ f_X على الأكثر عدد منته من نقاط الانقطاع من النوع الأول). وعندما تكون الدالة f_X ليست مستمرة في نقطة $x \in \mathbb{R}$ ، فعندئذ ستكون الدالة F_X غير قابلة للمفاضلة في هذه النقطة x ، وهذا يعني أنّ الرسم البياني للدالة F_X سوف يعاني من انكسار أو تدبب عند هذه النقطة، والأمثلة الآتية توضّح لنا ذلك.

(٥, ٣, ٢, ٧) أمثلة

١- ليكن X متغيراً عشوائياً مستمراً بدالة كثافة احتمالية:

$$f_X(x) = \cos(x) \cdot \mathbf{I}_{[0, \pi/2]}(x) \quad ; \forall x \in \mathbb{R}$$

فلاحظ أن دالة الكثافة الاحتمالية لهذا المتغير العشوائي تعاني من انقطاع عند النقطة

$x = 0$ ، ولنقم بتعيين دالة توزيع X .

الحل: لتعيين دالة توزيع X سنناقش الحالات الآتية:

أ- من أجل $x \geq 0$ لدينا الآتي:

$$F_X(x) = \int_{-\infty}^x f(t) dt \stackrel{\text{for } x \leq 0}{=} \int_{-\infty}^x \overbrace{f_X(t)}^0 dt = 0$$

ب- من أجل $0 < x \leq \pi/2$ لدينا الآتي:

$$F_X(x) = \int_{-\infty}^x f(t) dt \stackrel{\text{for } 0 < x \leq \pi/2}{=} \int_{-\infty}^0 \overbrace{f_X(t)}^0 dt + \int_0^x \overbrace{f_X(t)}^{\cos(t) \cdot \mathbf{I}_{[0, \pi/2]}(t)} dt$$

والتي نجد منها:

$$F_X(x) = \int_0^x \cos(t) \cdot \mathbf{I}_{[0, \pi/2]}(t) dt = \int_0^x \cos(t) dt = \left(\sin(t) \right) \Big|_0^x = (\sin(x) - 0) = \sin(x)$$

ج- من أجل $x > \pi/2$ لدينا الآتي:

$$\begin{aligned} F_X(x) &= \int_{-\infty}^x f(t) dt \stackrel{\text{for } x > \pi/2}{=} \int_{-\infty}^0 \overbrace{f_X(t)}^0 dt + \int_0^{\pi/2} \overbrace{f_X(t)}^{\cos(t) \cdot \mathbf{I}_{[0, \pi/2]}(t)} dt + \int_{\pi/2}^x \overbrace{f_X(t)}^0 dt \\ &= \int_0^{\pi/2} \cos(t) dt = \left(\sin t \right) \Big|_0^{\pi/2} = (1 - 0) = 1 \end{aligned}$$

ومن ثم يكون لدالة التوزيع الاحتمالية F_X العرض الآتي:


$$F_X(x) = \sin(x) \cdot \mathbf{I}_{[0, \pi/2]}(x) + \mathbf{I}_{[\pi/2, \infty)}(x) \quad ; \forall x \in \mathbb{R}$$

والتي يمكن عرضها وفقاً للصيغة الشرطية الآتية أيضاً:


$$F_X(x) = \begin{cases} 0 & \text{for } x \leq 0 \\ \sin(x) & \text{for } 0 < x \leq \pi/2 \\ 1 & \text{for } x > \pi/2 \end{cases}$$

حيث نلاحظ أن دالة التوزيع الاحتمالية لهذا المتغير العشوائي غير قابلة للمفاضلة عند

النقطة $x = 0$.



الشكل (١٩, ٥. أ) الرسم البياني لدالة الكثافة الاحتمالية



الشكل (١٩, ٥. ب) الرسم البياني لدالة التوزيع الاحتمالية

٢- ليكن X متغيراً عشوائياً مستمراً بدالة كثافة احتمالية f_X مُعطاة من خلال العلاقة الآتية:

$$f_X(x) = c \cdot \mathbf{I}_{[0,10]}(x) \quad ; \forall x \in \mathbb{R}$$


علماً أنَّ c ثابت حقيقي، ولنقم بتعيين قيمة هذا الثابت ومن ثم دالة التوزيع الاحتمالية F_X وبعد ذلك تقديم الرسم البياني لكل من f_X و F_X .

الحل: لتعيين الثابت c نعلم أنَّ:

$$1 = \int_{-\infty}^{\infty} f_X(x) dx = c \int_0^{10} dx = c \cdot (10 - 0) = 10c$$

التي نجد منها أنَّ $c = \frac{1}{10}$ ، ومن ثمَّ يصبح لدالة الكثافة الاحتمالية f_X العرض الآتي:

$$f_X(x) = \frac{1}{10} \mathbf{I}_{[0,10]}(x) \quad ; \forall x \in \mathbb{R}$$




فلاحظ أنَّ دالة الكثافة الاحتمالية لهذا المتغير العشوائي تعاني من نقطتي انقطاع عند النقطة $x = 0$ و $x = 10$ ، ولذلك سوف نلاحظ أنَّ دالة التوزيع الاحتمالية لهذا المتغير العشوائي ستكون غير قابلة للمفاضلة عند النقطتين $x = 0$ و $x = 10$. الشكل (٢٠، ٥. أ) الرسم البياني لدالة الكثافة الاحتمالية

الآن لتعيين دالة التوزيع الاحتمالية F_X نجد وبأسلوب مماثل لحل المثال السابق أنَّه من أجل كل $x \in \mathbb{R}$ لدينا:

$$F_X(x) = \int_{-\infty}^x f_X(t) dt = \frac{1}{10} \int_{-\infty}^x \mathbf{I}_{[0,10]}(t) dt = \frac{x}{10} \cdot \mathbf{I}_{(0,10]}(x) + \mathbf{I}_{(10,\infty)}(x)$$

والتي يمكن كتابتها على النحو الآتي أيضاً:



$$F_X(x) = \begin{cases} 0 & \text{for } x \leq 0 \\ \frac{x}{10} & \text{for } 0 < x \leq 10 \\ 1 & \text{for } x > 10 \end{cases}$$

الشكل (٢٠، ٥. ب) الرسم البياني لدالة التوزيع الاحتمالية

يمكننا باستخدام هذا المثال تقديم توضيح آخر للوصول إلى النتيجة التي تقول إنَّه من أجل X متغير عشوائي مستمر، و a قيمة حقيقية ثابتة يكون لدينا $P(X = a) = 0$ ، وذلك على النحو الآتي:

نعلم من المبرهنة (٣، ٢، ٢، ٥) أنَّ $P(a \leq X \leq b) = F_X(b) - F_X(a)$ ، ومن ثمَّ باستخدام المتغير العشوائي المعطى في هذا المثال يكون لدينا ما يلي:

$$P(2 \leq X \leq 4) = F_X(4) - F_X(2) = 0.2$$

$$P(2.5 \leq X \leq 3.5) = F_X(3.5) - F_X(2.5) = 0.1$$

$$P(2.95 \leq X \leq 3.05) = F_X(3.05) - F_X(2.95) = 0.01$$

$$P(2.995 \leq X \leq 3.005) = F_X(3.005) - F_X(2.995) = 0.001$$

$$P(2.9995 \leq X \leq 3.0005) = F_X(3.0005) - F_X(2.9995) = 0.0001$$

وهكذا نلاحظ أنه عندما القيمة الراجعة على X من الأعلى تسعى إلى الـ 3 وفي الوقت نفسه القيمة المرجوحة بـ X من الأدنى تسعى إلى الـ 3 أيضاً، فإن قيمة الاحتمال المقدم سوف يسعى إلى $P(X = 3)$ ، وأما القيمة المقابلة لهذا الاحتمال فإنها تسعى إلى الصفر وضوحاً.

٣- ليكن X متغيراً عشوائياً مستمراً بدالة كثافة احتمالية f_X معطاة من خلال العلاقة الآتية:

$$f_X(x) = \begin{cases} c\sqrt{x} & \text{for } 0 < x < 1 \\ 0 & \text{otherwise} \end{cases}$$

ولنقم بما يلي:

أ- تعيين قيمة الثابت c ، ومن ثم رسم بيان الدالة f_X .

ب- تعيين دالة التوزيع الاحتمالية لـ X .

ج- استخدم دالة التوزيع الاحتمالية لـ X في حساب الاحتمال $P(0.3 < X < 0.6)$.

الحل: من أجل الفقرة:

أ- نعلم أن $\int_{-\infty}^{+\infty} f_X(x) dx = 1$ ، ومن ثم يكون لدينا:

$$\begin{aligned} 1 &= \int_{-\infty}^{\infty} f_X(x) dx = \int_{-\infty}^0 \overbrace{f_X(x)}^0 dx + \int_0^1 \overbrace{f_X(x)}^{c\sqrt{x}} dx + \int_1^{\infty} \overbrace{f_X(x)}^0 dx \\ &= \int_0^1 c\sqrt{x} dx = c \left(\frac{2}{3} x^{\frac{3}{2}} \Big|_0^1 \right) = \frac{2c}{3} (1 - 0) = \frac{2c}{3} \end{aligned}$$


والتي نجد منها أن $c = \frac{3}{2}$ ، ومن ثم يكون لدالة الكثافة الاحتمالية f_X العرض الآتي.

$$f_X(x) = \begin{cases} \frac{3}{2}\sqrt{x} & \text{for } 0 < x < 1 \\ 0 & \text{elseswhere} \end{cases}$$


فلاحظ أن دالة الكثافة الاحتمالية لهذا المتغير العشوائي تعاني من نقطة انقطاع عند $x = 1$ (انظر الشكل (٥، ٢١) أ)، ولذلك سوف نلاحظ أن دالة التوزيع الاحتمالية لهذا المتغير العشوائي ستكون غير قابلة للمفاضلة عند هذه النقطة (انظر الشكل (٥، ٢١) ب).

ب- لتعيين دالة التوزيع الاحتمالية F_X نجد وبأسلوب مماثل لحل المثال الأول السابق أنه من أجل كل $x \in \mathbb{R}$ لدينا:

$$F_X(x) = \int_{-\infty}^x f_X(t) dt = \int_{-\infty}^x \frac{3}{2} t^{\frac{1}{2}} \cdot \mathbf{I}_{[0,1]}(t) dt = x^{\frac{3}{2}} \cdot \mathbf{I}_{(0,1]}(x) + \mathbf{I}_{(1,\infty)}(x)$$



الشكل (٥، ٢١) ب) الرسم البياني لدالة التوزيع الاحتمالية



الشكل (٥، ٢١) أ) الرسم البياني لدالة الكثافة الاحتمالية

ج- لحساب $P(0.3 < X < 0.6)$ لدينا:

$$P(0.3 < X < 0.6) = F_X(0.6) - F_X(0.3) = 0.6^{\frac{3}{2}} - 0.3^{\frac{3}{2}} = 0.465 - 0.164 = 0.301$$

وبهذا ينتهي حل المثال.

٤- لتكن f دالة حقيقية معرفة على \mathbb{R} كما يلي:

$$f(x) = \frac{1}{e-1} e^x \cdot \mathbf{I}_{[0,1]}(x) \quad ; \forall x \in \mathbb{R}$$

فلاحظ أن هذه الدالة غير سالبة على \mathbb{R} ، ولدينا:


$$\int_{-\infty}^{\infty} f(x) dx = \frac{1}{e-1} \int_0^1 e^x dx = 1$$

وهذا يعني أن هذه الدالة تصلح لأن تكون دالة كثافة احتمالية لمتغير عشوائي X ، بمعنى أنه يوجد متغير عشوائي X بحيث تكون هذه الدالة هي دالة كثافة احتمالية له للاطلاع على رسمها البياني (انظر الشكل (٢٢، ٥.أ)).


الآن لو رمزنا لهذه الدالة بـ f_X ، فعندئذ يكون لدالة التوزيع F_X العرض الآتي من أجل كل $x \in \mathbb{R}$:

$$F_X(x) = \int_{-\infty}^x f_X(t) dt = \frac{1}{e-1} \int_{-\infty}^x e^t dt = \frac{e^x - 1}{e-1} \mathbf{I}_{(0,1]}(x) + \mathbf{I}_{(1,\infty)}(x)$$

حيث نلاحظ بوضوح أن دالة التوزيع الاحتمالية لـ X هي دالة غير قابلة للمفاضلة عند النقطة $x = 1$ (انظر الشكل (٢٢، ٥.ب)).



الشكل (٢٢، ٥.ب) الرسم البياني لدالة التوزيع الاحتمالية



الشكل (٢٢، ٥.أ) الرسم البياني لدالة الكثافة الاحتمالية

٥- لتكن F_X دالة توزيع احتمالية لمتغير عشوائي X معطاة من خلال العلاقة الآتية (ورسمها البياني يقدمه الشكل (٢٣، ٥.أ)):

$$F_X(x) = (4x^3 - 6x^2 + 3x) \mathbf{I}_{(0,1]}(x) + \mathbf{I}_{(1,\infty)}(x) \quad ; \forall x \in \mathbb{R}$$


ولنقم بتعيين دالة الكثافة الاحتمالية الموافقة لـ F_X .

الحل: باستخدام العلاقة $[5, 25]$ يكون من أجل كل $x \in (0, 1)$ لدينا ما يلي:

$$f_X(x) = \frac{dF_X(x)}{dx} = (12x^2 - 12x + 3) \mathbf{I}_{(0,1)}(x)$$

وأما من أجل قيم x التي لا تنتمي للفترة $(0, 1)$ فلدينا $f_X(x) = 0$ لأن F_X ثابتة على $\mathbb{R} \setminus (0, 1)$ ، وأخيراً الرسم البياني لـ F_X

نجد في الشكل (٢٣، ٥. ب) الآتي.



(٥، ٤) المتجهات العشوائية وتوزيعاتها الاحتمالية

Random Vectors and their Probability Distributions

لقد قمنا فيما سبق بدراسة متغيرات عشوائية وحيدة البعد. فيما يلي سنقدم دراسة لمتغيرات عشوائية متعددة الأبعاد يُطلق عليها اسم **متجهات عشوائية** Random Vectors. إنَّ ضرورة التعامل مع متغيرات عشوائية متعددة الأبعاد ينبع من متطلبات الدراسة الاحتمالية لبعض التجارب العشوائية في مجالات التصنيع، والاتصالات، وعلم الحياة، وعلوم كثيرة أخرى، حيث يقف المتغير العشوائي وحيد البعد عاجزاً عن تمثيل مثل تلك التجارب أو دراستها، فعلى سبيل المثال لو أردنا القيام بإجراء دراسة حول تطور الطول والوزن مع عمر الأطفال حتى سن مُعين، فعندئذ النتائج المتمخضة عن هذه التجربة تعطينا ثلاثة نماذج من القيم العشوائية الأول خاص بالقيم الناتجة عن الطول ونحتاج لذلك متغيراً عشوائياً X_1 ، والثاني خاص بالقيم الناتجة عن الوزن ويمثله متغير عشوائي ثانٍ X_2 ، وأخيراً متغير عشوائي ثالث خاص بالقيم الناتجة عن العمر ويمثله متغير عشوائي آخر X_3 ، وبالمحصلة نجد أنَّ نتائج دراسة كل طفل يُمثل بثلاثية (x_1, x_2, x_3) كقيمة عشوائية للمتجه (X_1, X_2, X_3) لدى تطبيقه على ذلك الطفل، ويلاحظ هنا أنَّ المتجه (X_1, X_2, X_3) يأخذ قيمة في R^3 . بالطبع كان بإمكاننا توسيع أبعاد هذا المتجه إذا ما قمنا بإضافة أي ظاهرة من ظواهر الجسم البشري مثل الحرارة ومحيط الرأس...

إنَّ الخطوة الأولى لتعميم الدراسة السابقة هي دراسة التوزيعات الاحتمالية على R^n مع $n \in \mathbb{N}$ التي ينتج عنها دراسة توزيعات المتجهات العشوائية علماً أنَّنا سنركز دراستنا على المتجهات العشوائية الحقيقية فقط، وأكثر من ذلك، لن نتوسع كثيراً في دراسة هذا الموضوع بل سنكتفي ببعض المفاهيم والنتائج الأساسية والمهمة.

(٥، ٤، ١) مفهوم المتجه العشوائي

لقد قمنا سابقاً بتقديم المتجه العشوائي من خلال أحد الأمثلة على العناصر العشوائية (المثال ٢ / من الفقرة (١، ٢، ٥))، وفيما يلي سنعيد صياغته على نحو آخر كالآتي.

لتكن X_1, X_2, \dots, X_n متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ نجد أنَّ التطبيق:

$$(X_1, X_2, \dots, X_n) : \Omega \longrightarrow R^n$$

$$\omega \mapsto (X_1, X_2, \dots, X_n)(\omega) := (X_1(\omega), X_2(\omega), \dots, X_n(\omega))$$

هو عنصر عشوائي فوق $[\Omega, \mathcal{A}, P]$ وبقیم في الفضاء المقيس $[R^n, \mathcal{B}^n]$ ؛ وذلك لأنَّه من أجل أي B_1, B_2, \dots, B_n من \mathcal{B} لدينا ما يلي مُحققاً:

$$\begin{aligned} (X_1, X_2, \dots, X_n)^{-1} (B_1 \times B_2 \times \dots \times B_n) &= \{ \omega \in \Omega ; X_1(\omega) \in B_1 \wedge X_2(\omega) \in B_2 \wedge \dots \wedge X_n(\omega) \in B_n \} \\ &= \bigcap_{k=1}^n X_k^{-1}(B_k) \in \mathcal{F} \end{aligned}$$

وذلك لأن X_1, X_2, \dots, X_n متغيرات عشوائية فوق $[\Omega, \mathcal{A}, P]$ و \mathcal{A} مغلق بالنسبة إلى عملية التقاطع المنتهي وغير المنتهي العدود. علماً أن \bigwedge هو الرمز المنطقي الذي يشير إلى عبارة (و and)، وهذا الرمز يكثر استخدامه في مجال دراسة المتجهات العشوائية. هكذا يمكننا إعادة تقديم المتجه العشوائي من خلال التعريف الآتي.

(١, ٤, ٥) تعريف (المتجه العشوائي)

لتكن X_1, X_2, \dots, X_n متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ يدعى (X_1, X_2, \dots, X_n) متجهاً عشوائياً ذا بُعد يساوي n (أو منته البعد)، وكنا قد رمزنا له بـ \mathbb{X}_n ، أي إننا سنكتب:

$$\mathbb{X}_n \triangleq (X_1, X_2, \dots, X_n) \quad [5,26]$$

(٢, ٤, ٥) ملاحظات

١- يمكننا من أجل أي متجه عشوائي \mathbb{X}_n فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ إيجاد n متغير عشوائي X_1, X_2, \dots, X_n فوق $[\Omega, \mathcal{A}, P]$ بحيث يكون من أجل كل $\omega \in \Omega$ لدينا:

$$\mathbb{X}_n(\omega) = (X_1(\omega), X_2(\omega), \dots, X_n(\omega)) \quad [5,27]$$

ولإثبات ذلك لننمّن النظر في التركيب الآتي:

$$\begin{aligned} \Omega &\xrightarrow{\mathbb{X}_n} \mathbb{R}^n \xrightarrow{\Pi_i} \mathbb{R} \\ \omega &\mapsto \mathbb{X}_n(\omega) = (x_1, \dots, x_n) \mapsto \Pi_i(x_1, \dots, x_n) = x_i \end{aligned}$$

علماً أن Π_i مع $N_n \ni i$ هي دوال الإسقاط Projection Functions على \mathbb{R}^n ، فعندئذ لو أخذنا:

$$X_i = \Pi_i \circ \mathbb{X}_n \quad ; \quad i \in N_n \quad [5,28]$$

فإننا نجد أن X_1, X_2, \dots, X_n هي متغيرات عشوائية فوق $[\Omega, \mathcal{A}, P]$ ، وهذا يعني أنه من أجل أي متجه عشوائي \mathbb{X}_n على $[\Omega, \mathcal{A}, P]$ يوجد بالفعل n متغير عشوائي X_1, X_2, \dots, X_n فوق $[\Omega, \mathcal{A}, P]$ بحيث تكون العلاقة [5,28] مُحَقَّقة.

٢- إذا كان $\mathbb{X}_n = (X_1, X_2, \dots, X_n)$ متجهاً عشوائياً مركبته X_1, X_2, \dots, X_n متغيرات عشوائية عقدية، فعندئذ يُقال عن \mathbb{X}_n إنه متجه عشوائي عقدي.

(٢, ٤, ٥) دالة التوزيع الاحتمالية لمتجه عشوائي Distribution Function of a Random Vector

الآن، وبما أن قيم المتجه العشوائي \mathbb{X}_n في \mathbb{R}^n عشوائية، فإنه سيقابل الفضاء الاحتمالي $[\Omega, \mathcal{A}, P]$ فضاءً احتمالياً مولّداً من \mathbb{X}_n ، وهذا يعني ضرورة وجود قياس احتمالي على $[\mathbb{R}^n, \mathcal{B}^n]$ مولّداً من \mathbb{X}_n ، وهذا بدوره يوصلنا إلى مفهوم قانون توزيع متجه عشوائي والذي سنقدمه من خلال التعريف الآتي.

(١, ٢, ٤, ٥) تعريف (قانون توزيع متجه عشوائي Distribution Law of a Random Vector)

ليكن \mathbb{X}_n متجهاً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ يكون:

$$P_{\mathbb{X}_n}(B) = (P \circ \mathbb{X}_n^{-1})(B) = P(\mathbb{X}_n^{-1}(B)) \quad [5,29]$$

هو القياس المولد من \mathbb{X}_n ، ويبرهن بسهولة على أنه قياس احتمالي على $[\mathbb{R}^n, \mathcal{R}^n]$. إن القياس $P_{\mathbb{X}_n}$ يدعى **قانون توزيع المتجه العشوائي** \mathbb{X}_n .

(٢, ٢, ٤, ٥) ملاحظة

بما أنه من أجل أي متجه عشوائي \mathbb{X}_n فوق $[\Omega, \mathcal{A}, P]$ يوجد n متغير عشوائي X_1, X_2, \dots, X_n و X_n بحيث يكون $\mathbb{X}_n = (X_1, X_2, \dots, X_n)$ ، فإن قانون توزيع \mathbb{X}_n يسمى في بعض الأحيان **قانون التوزيع المشترك** للمتغيرات العشوائية X_1, X_2, \dots, X_n ويرمز له عندئذ بـ P_{X_1, X_2, \dots, X_n} ، ولذلك من أجل $B := B_1 \times B_2 \times \dots \times B_n$ من \mathcal{R}^n يمكننا أن نكتب ما يلي:

$$P_{\mathbb{X}_n}(B) = P_{X_1, X_2, \dots, X_n}(B_1 \times B_2 \times \dots \times B_n) = P(X_1 \in B_1, X_2 \in B_2, \dots, X_n \in B_n) \quad [5,30]$$

الآن، وبعد أن قمنا بتعريف قانون توزيع متجه عشوائي \mathbb{X}_n يمكننا الانتقال إلى المرحلة التالية والمتمثلة بتعيين دالة توزيع المتجه العشوائي \mathbb{X}_n .

(٣, ٢, ٤, ٥) تعريف (دالة توزيع متجه عشوائي)

ليكن \mathbb{X}_n متجهاً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، ولنعرّف من أجل هذا المتجه العشوائي دالة حقيقية $F_{\mathbb{X}_n}$ على \mathbb{R}^n كما يلي:

$$F_{\mathbb{X}_n} : \mathbb{R}^n \longrightarrow \mathbb{R} ; \vec{x}^n = (x_1, x_2, \dots, x_n) \mapsto F_{\mathbb{X}_n}(\vec{x}^n) := P\left(\mathbb{X}_n \in \prod_{k=1}^n (-\infty, x_k)\right) \quad [5,31]$$

فعندئذ يُطلق على الدالة $F_{\mathbb{X}_n}$ اسم **دالة توزيع المتجه العشوائي** \mathbb{X}_n .

(٤, ٢, ٤, ٥) ملاحظات:

١- في حال أخذنا $\mathbb{X}_n = (X_1, X_2, \dots, X_n)$ فإنه يمكن كتابة العلاقة [5,31] على النحو الآتي أيضاً:

$$F_{\mathbb{X}_n}(\vec{x}^n) = P(X_1 < x_1, X_2 < x_2, \dots, X_n < x_n) \quad [5,32]$$

وذلك لأن:

$$\begin{aligned} F_{\mathbb{X}_n}(\vec{x}^n) &= P\left(\mathbb{X}_n \in \prod_{k=1}^n (-\infty, x_k)\right) = P\left(\mathbb{X}_n \in (-\infty, x_1) \times (-\infty, x_2) \times \dots \times (-\infty, x_n)\right) \\ &= P\left((X_1, X_2, \dots, X_n) \in (-\infty, x_1) \times (-\infty, x_2) \times \dots \times (-\infty, x_n)\right) \\ &= P\left(X_1 \in (-\infty, x_1) \wedge X_2 \in (-\infty, x_2) \wedge \dots \wedge X_n \in (-\infty, x_n)\right) \\ &= P(X_1 < x_1, X_2 < x_2, \dots, X_n < x_n) \end{aligned}$$

٢- إن دالة توزيع متجه عشوائي \mathbb{X}_n هي دالة التوزيع نفسها لقانون توزيع \mathbb{X}_n ؛ وذلك لأنه من أجل كل $\vec{x}^n \in \mathbb{R}^n$ لدينا:

$$\begin{aligned} F_{P_{\mathbb{X}_n}}(\vec{x}^n) &= P_{\mathbb{X}_n}((-\infty, x_1) \times (-\infty, x_2) \times \dots \times (-\infty, x_n)) \\ &= P\left(\mathbb{X}_n^{-1}((-\infty, x_1) \times (-\infty, x_2) \times \dots \times (-\infty, x_n))\right) \\ &= P\left(\mathbb{X}_n \in (-\infty, x_1) \times (-\infty, x_2) \times \dots \times (-\infty, x_n)\right) = F_{\mathbb{X}_n}(\vec{x}^n) \end{aligned}$$

٣- بما أن \mathbb{X}_n يمكن كتابته على الشكل (X_1, X_2, \dots, X_n) دوماً، فإنه يُطلق على الدالة $F_{\mathbb{X}_n}$ اسم **دالة التوزيع المشتركة**

Joint Distribution Function للمتغيرات العشوائية X_1, X_2, \dots, X_n ويرمز لها حيثئذ بـ F_{X_1, X_2, \dots, X_n} ، ومن ثم يمكننا من أجل أي $\vec{x}^n = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$ أن نكتب الآتي:

$$F_{\mathbb{X}_n}(\vec{x}^n) = F_{X_1, X_2, \dots, X_n}(x_1, x_2, \dots, x_n) = P(X_1 < x_1, X_2 < x_2, \dots, X_n < x_n) \quad [5,33]$$

٤- إن تعريف دالة توزيع متجه عشوائي هو حالة خاصة من تعريف دالة التوزيع الاحتمالية لقياس احتمالي (كما ر ذلك من أجل متغير عشوائي في الفقرة ٣/ من (٥, ٢, ٢, ٢))، فلو كان S قياساً احتمالياً على $[\mathbb{R}^n, \mathcal{R}^n]$ ، وعرفنا من أجله دالة حقيقية F_S على \mathbb{R}^n كما يلي:

$$F_S : \mathbb{R}^n \longrightarrow \mathbb{R} ; \vec{x}^n = (x_1, x_2, \dots, x_n) \mapsto F_S(\vec{x}^n) := S\left(\prod_{k=1}^n (-\infty, x_k)\right) \quad [5,34]$$

فعندئذ (وبطريقة مماثلة لما سبق في الملاحظة ٣/ من الفقرة (٥, ٢, ٢, ٢)) تنتج دالة التوزيع الاحتمالية $F_{\mathbb{X}_n}$ من الدالة F_S عندما نأخذ

$$S = P_{\mathbb{X}_n} \text{ حيث يمكن تبيان أن } F_{P_{\mathbb{X}_n}} = F_{\mathbb{X}_n}.$$

(٥, ٤, ٣) خصائص دوال التوزيع الاحتمالية على \mathbb{R}^n

فيما يلي نقدم مبرهنة (وستقبلها دون برهان، ولن يود الاطلاع على البرهان يمكنه الرجوع إلى [64]) تزودنا بأهم الخصائص المميزة لدوال التوزيع الاحتمالية على \mathbb{R}^n .

(٥, ٤, ٣, ١) مبرهنة

لتكن $F_{\mathbb{X}_n}$ دالة توزيع متجه عشوائي \mathbb{X}_n فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ من أجل كل $\vec{x}^n = (x_1, x_2, \dots, x_n)$ من \mathbb{R}^n يكون ما يلي محققاً:

e_1^* - الدالة $F_{\mathbb{X}_n}$ غير متناقصة على كل مركبة x_k من مركبات المتجه \vec{x}^n .

e_2^* - إن السلوك الحدي لدالة التوزيع $F_{\mathbb{X}_n}$ يحقق العلاقتين الآتيتين:

أ- إذا وجد على الأقل $k \in \mathbb{N}_n$ بحيث يمكن للمركبة x_k أن تسعى إلى $-\infty$ (وسنرمز لذلك بـ $x_k \downarrow -\infty$) فعندئذ سيكون لدينا:

$$\lim_{x_k \downarrow -\infty} F_{\mathbb{X}_n}(x_1, \dots, x_{k-1}, x_k, x_{k+1}, \dots, x_n) = 0 \quad [5,35]$$

ب- إذا كان من أجل كل $k \in \mathbb{N}_n$ بحيث يمكن للمركبة x_k أن تسعى إلى $+\infty$ (وسنرمز لذلك بـ $x_k \uparrow +\infty$) فعندئذ سيكون لدينا:

$$\lim_{\substack{x_1 \uparrow +\infty \\ x_2 \uparrow +\infty \\ \vdots \\ x_n \uparrow +\infty}} F_{\mathbb{X}_n}(x_1, x_2, \dots, x_n) = 1 \quad [5,36]$$

e_3^* - الدالة $F_{\mathbb{X}_n}$ مستمرة من اليسار عند كل مركبة x_k من مركبات المتجه \vec{x}^n .

(٥, ٤, ٣, ٢) نتائج

١- من أجل كل $-\infty < a_1 < b_1 \leq +\infty$ و $-\infty < a_2 < b_2 \leq +\infty$ لدينا ما يلي محققاً:

$$F_{\mathbb{X}_n}(b_1, b_2) - F_{\mathbb{X}_n}(a_1, b_2) - F_{\mathbb{X}_n}(b_1, a_2) + F_{\mathbb{X}_n}(a_1, a_2) \geq 0 \quad [5,37-a]$$

وهذه العلاقة تكافئ العلاقة الآتية من أجل كل $x_1, x_2 \in \mathbb{R}$ و $0 < h_1, h_2$:


$$F_{X_n}(x_1+h_1, x_2+h_2) - F_{X_n}(x_1+h_1, x_2) - F_{X_n}(x_1, x_2+h_2) + F_{X_n}(x_1, x_2) \geq 0 \quad [5,37-b]$$

الإثبات: لنقم بتعريف المجموعات (الساحات) الآتية:

$$A := (-\infty, b_1) \times (-\infty, b_2) \quad \& \quad C := (-\infty, a_1) \times (-\infty, a_2)$$

$$B_1 := (-\infty, b_1) \times (-\infty, a_2) \quad \& \quad B_2 := (-\infty, a_1) \times (-\infty, b_2)$$

والأشكال الأربعة الآتية (الشكل (٥, ٢٤)) تعرض لنا هذه المجموعات.



الشكل (٥, ٢٤)

فعدنئذ لدينا ما يلي:

$$\begin{aligned} 0 \leq P_{X_n}([a_1, b_1] \times [a_2, b_2]) &= P_{X_n}(\{(-\infty, b_1) \setminus (-\infty, a_1)\} \times \{(-\infty, b_2) \setminus (-\infty, a_2)\}) \\ &= P_{X_n}((A \setminus (B_1 \cup B_2)) \cup C) = P_{X_n}(A) - P_{X_n}(B_1) - P_{X_n}(B_2) + P_{X_n}(C) \end{aligned}$$

ومنه يمكننا أن نكتب الآتي:

$$\begin{aligned} P_{X_n}([a_1, b_1] \times [a_2, b_2]) &= P_{X_n}((-\infty, b_1) \times (-\infty, b_2)) - P_{X_n}((-\infty, b_1) \times (-\infty, a_2)) \\ &\quad - P_{X_n}((-\infty, a_1) \times (-\infty, b_2)) + P_{X_n}((-\infty, a_1) \times (-\infty, a_2)) \\ &= F_{X_n}(b_1, b_2) - F_{X_n}(b_1, a_2) - F_{X_n}(a_1, b_2) + F_{X_n}(a_1, a_2) \end{aligned}$$

وبهذا يتم الإثبات.

٢- من النتيجة السابقة يمكننا أن نكتب المتباينة الآتية من أجل متجه عشوائي $X_2 = (X_1, X_2)$:

$$\begin{aligned} P(a_1 \leq X_1 < b_1, a_2 \leq X_2 < b_2) &= F_{X_1, X_2}(b_1, b_2) - F_{X_1, X_2}(a_1, b_2) \\ &\quad - F_{X_1, X_2}(b_1, a_2) + F_{X_1, X_2}(a_1, a_2) \geq 0 \end{aligned} \quad [5,38]$$

علماً أنَّ $-\infty < a_1 < b_1 \leq +\infty$ و $-\infty < a_2 < b_2 \leq +\infty$.

سنعرض فيما يلي الشروط الكافية لكي تكون دالة حقيقية F على \mathbb{R}^n دالة توزيع احتمالية، وسنمهد لذلك بالتعريف الآتي.

(٥, ٤, ٣, ٣) تعريف

لنرمز بـ $\mathbf{F}(\mathbb{R}^n)$ لمجموعة كل الدوال الحقيقية المعرفة على \mathbb{R}^n ، ولنأخذ $0 < h$ عدد حقيقي، ولنعرّف من أجل كل $N_n \ni k$ مؤثراً Δ_h^k Operator على $\mathbf{F}(\mathbb{R}^n)$ كما يلي:

$$\Delta_h^k : \mathbf{F}(\mathbb{R}^n) \longrightarrow \mathbf{F}(\mathbb{R}^n)$$

$$f \mapsto \Delta_h^k(f) := f(x_1, \dots, x_{k-1}, x_k + h, x_{k+1}, \dots, x_n) - f(x_1, \dots, x_k, \dots, x_n) \quad [5,39]$$

بمساعدة هذا التعريف يمكننا الحصول على النتيجة المهمة الآتية.

(٥, ٤, ٣, ٤) نتيجة

لتكن $F_{\mathbb{X}_2}$ دالة توزيع متّجه عشوائي \mathbb{X}_2 ، فعندئذ من أجل كل $x_1, x_2 \in \mathbb{R}$ و $0 < h_2, h_1$ ستكون المتباينة الآتية مُحَقَّقة:

$$\Delta_{h_2}^2 \Delta_{h_1}^1 F_{\mathbb{X}_2}(x_1, x_2) \geq 0 \quad [5,40]$$

وذلك لأن:

$$\begin{aligned} \Delta_{h_2}^2 \left(\Delta_{h_1}^1 F_{\mathbb{X}_2}(x_1, x_2) \right) &= \Delta_{h_2}^2 \left(F_{\mathbb{X}_2}(x_1 + h_1, x_2) - F_{\mathbb{X}_2}(x_1, x_2) \right) \\ &= \Delta_{h_2}^2 \left(F_{\mathbb{X}_2}(x_1 + h_1, x_2) \right) - \Delta_{h_2}^2 \left(F_{\mathbb{X}_2}(x_1, x_2) \right) \\ &= F_{\mathbb{X}_2}(x_1 + h_1, x_2 + h_2) - F_{\mathbb{X}_2}(x_1 + h_1, x_2) - F_{\mathbb{X}_2}(x_1, x_2 + h_2) + F_{\mathbb{X}_2}(x_1, x_2) \geq 0 \end{aligned}$$

سنقبل المبرهنة الآتية دون برهان حيث تُعدّ تعميماً للنتيجة السابقة.

(٥, ٤, ٣, ٥) مبرهنة

لتكن $F_{\mathbb{X}_n}$ دالة توزيع متّجه عشوائي \mathbb{X}_n مع $N \ni n$ مثبت، فعندئذ دالة التوزيع $F_{\mathbb{X}_n}$ تُحَقِّق الخاصية الآتية:

e_4^* - من أجل أيّ متّجه $(x_1, x_2, \dots, x_n) \in \mathbb{R}^n$ وأية أعداد حقيقية موجبة h_1, h_2, \dots و $0 < h_n$ ، سيكون لدينا:

$$\Delta_{h_n}^n \Delta_{h_{n-1}}^{n-1} \dots \Delta_{h_2}^2 \Delta_{h_1}^1 F_{\mathbb{X}_2}(x_1, x_1, \dots, x_n) \geq 0 \quad [5,41]$$

(٥, ٤, ٣, ٦) ملاحظات

١- إن المتباينة السابقة [5,38] يمكن تعميمها على \mathbb{R}^n إلا أنَّ الشكل الناتج سيكون أكثر تعقيداً، علماً أنه يمكن استنتاجها من خلال الخاصية e_4^* السابقة.

٢- إنَّ أية دالة توزيع احتمالية على \mathbb{R}^n تُحَقِّق الخواص e_1^* و e_2^* و e_3^* ، ولكن العكس ليس صحيحاً، أي إنه ليست كل دالة حقيقية معرفة على \mathbb{R}^n وتُحَقِّق الخواص e_1^* و e_2^* و e_3^* هي دالة توزيع احتمالية، فلو أخذنا على سبيل المثال الدالة الحقيقية F والمعرفة على \mathbb{R}^2 كما يلي:

$$F(x, y) := \begin{cases} 1 & \text{for } x > 0, y > 1 \text{ or } x > 2, y > 0 \\ 0 & \text{otherwise.} \end{cases}$$

فنجِد أنَّ هذه الدالة تُحقِّق الخواص e_1^* و e_2^* و e_3^* ، ولكن نلاحظ أنَّه من أجل $h_1 = h_2 = 2$ و $x_1 = x_2 = 1$ لدينا الآتي:

$$F(3,3) - F(3,1) - F(1,3) + F(1,1) = 1 - 1 - 1 + 0 = -1 < 0$$

وهذا يعني أنَّ الدالة F لا تُحقِّق المتباينة [5,37-a] من أجل النقطة $(1,1)$ والقيمتين $h_1 = h_2 = 2$ ، ومن ثمَّ فإنَّها لا تصلح أن تكون دالة توزيع احتمالية على \mathbb{R}^2 .

٣- لقد بيَّنت لنا الملاحظة السابقة أنَّ خصائص دوال التوزيع للمتجهات العشوائية قد تختلف عن خصائص دوال التوزيع للمتغيرات العشوائية الوحيدة البعد، ففي الواقع توجد عدَّة فوارق بين دوال التوزيع للمتجهات العشوائية ودوال التوزيع للمتغيرات العشوائية ذات البعد الواحد سنذكر منها فارقين مهمين هما:

أ- نلاحظ أنَّ الخاصية e_1^* تنتج من الخاصية e_4^* ، ومن ثمَّ فإنَّ العلاقات e_2^* و e_3^* و e_4^* ، تُمَيِّز دالة التوزيع الاحتمالية بشكل تام، بمعنى أنَّ كل دالة توزيع احتمالية $F_{\mathbb{X}_n}$ تُحقِّق الخواص e_2^* و e_3^* و e_4^* ، والعكس صحيح أيضاً، أي إنَّه إذا كانت F دالة حقيقية معرفة على \mathbb{R}^n وتُحقِّق الخواص e_2^* و e_3^* و e_4^* فإنَّ هذه الدالة F ستكون دالة توزيع احتمالية على \mathbb{R}^n ، بمعنى أنَّه يوجد متجه عشوائي \mathbb{X}_n بحيث تكون F هي دالة توزيعه الاحتمالية.

ب- نعلم أنَّه إذا كان X متغيراً عشوائياً مستمراً فإنَّ دالة توزيعه F_X تكون مستمرة على \mathbb{R} ، ولكنَّ هذه الخاصية تصبح غير صحيحة من أجل المتجهات العشوائية، وذلك لأنَّه توجد دوال توزيع احتمالية لمتجهات عشوائية مستمرة (انظر تعريف المتجه العشوائي المستمر في فقرة تصنيف المتجهات العشوائية) تعاني من نقط انقطاع، فعلى سبيل المثال لو أخذنا $\mathbb{X}_2 = (X_1, X_2)$ متجهاً عشوائياً بدالة توزيع $F_{\mathbb{X}_2}$ معطاة من خلال العلاقة الآتية:

$$F_{\mathbb{X}_2}(x_1, x_2) = \begin{cases} 0 & \text{for } x_1 \leq 0 \quad \text{or} \quad x_2 \leq 0 \\ x_1 \cdot x_2 & \text{for } 0 < x_1 \leq 1 \quad \text{and} \quad 0 < x_2 \leq \frac{1}{2} \\ \frac{1}{2} x_1 & \text{for } 0 < x_1 \leq 1 \quad \text{and} \quad x_2 > \frac{1}{2} \\ 2 x_2 & \text{for } x_1 > 1 \quad \text{and} \quad 0 < x_2 \leq \frac{1}{2} \\ 1 & \text{for } x_1 > 1 \quad \text{and} \quad x_2 > \frac{1}{2} \end{cases}$$

فنجِد أنَّ للمتجه العشوائي \mathbb{X}_2 احتمال يساوي $\frac{1}{2}$ عند النقاط $x_1 = 1$ و $0 \leq x_2 \leq \frac{1}{2}$ وذلك لأنَّ:

$$P\left(X_1 = 1, 0 \leq X_2 \leq \frac{1}{2}\right) = F_{\mathbb{X}_2}\left(1, \frac{1}{2}\right) - F_{\mathbb{X}_2}(1, 0) = \frac{1}{2} - 0 = \frac{1}{2}$$

ومن جهة أخرى واضح أنَّ كل نقطة ذات إحداثي $(1, x_2)$ مع $\frac{1}{2} < x_2 < \infty$ هي نقطة انقطاع لدالة التوزيع $F_{\mathbb{X}_2}$ رغم أنَّ المتجه العشوائي \mathbb{X}_2 ليس له قفزات على الفترة $\frac{1}{2} < x_2 < \infty$ وعند $x_1 = 1$.

(٤, ٤, ٥) تصنيف المتجهات العشوائية Classification of Random Vectors

لقد قمنا فيما سبق بدراسة موجزة نسبياً لدوال التوزيع الاحتمالية لمتجهات عشوائية، ومن ثم أوضحنا بعض الخصائص المهمة لهذه الدالة، ولكن لدى دراسة الكثير من الظواهر والتجارب العشوائية تصادفنا متجهات عشوائية مختلفة الأصناف فمنها ذات مركبات لمتغيرات عشوائية متقطعة، وأخرى ذات مركبات لمتغيرات عشوائية مستمرة، وثالثة ذات مركبات لمتغيرات عشوائية متقطعة ومستمرة أو غير مستمرة. لذلك نجد أنه لا بد من التمييز بين هذه المتجهات العشوائية لتبسيط دراستها وتوضيح العمليات الحسابية بشأنها، وفي كتابنا هذا سنركز دراستنا على نموذجين فقط وهما:

- المتجهات العشوائية المتقطعة،

- المتجهات العشوائية المستمرة.

(١, ٤, ٤, ٥) المتجهات العشوائية المتقطعة Discrete Random Vectors

على غرار ما قمنا به من أجل المتغيرات العشوائية الوحيدة البعد سنقوم أولاً بتعريف المتجه العشوائي المتقطع الذي يقدمه لنا التعريف الآتي.

(١, ١, ٤, ٤, ٥) تعريف (المتجه العشوائي المتقطع)

ليكن X_n متجهاً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فإذا كانت جميع مركبات هذا المتجه هي متغيرات عشوائية متقطعة، فعندئذ يُقال عن X_n إنه متجه عشوائي متقطع.

(٢, ١, ٤, ٤, ٥) ملاحظات


١- بفرض أن $X_n = (X_1, X_2, \dots, X_n)$ متجه عشوائي متقطع بحيث إنه من أجل كل $k \in \mathbb{N}_n$ للمركبة X_k مجموعة القيم $X_k = \{x_{ki} ; i_k \in I_k \subseteq \mathbb{N}\}$ ، فعندئذ تسمى النقاط $(x_{1i_1}, x_{2i_2}, \dots, x_{ni_n})$ مواضع قفزات للمتجه العشوائي X_n ، في حين أن قيمة احتمال أن يأخذ المتجه العشوائي X_n النقطة $(x_{1i_1}, x_{2i_2}, \dots, x_{ni_n})$ تدعى الكتلة الاحتمالية للمتجه العشوائي X_n عند هذا النقطة، ويرمز لهذه الكتلة الاحتمالية بـ $p_{i_1 i_2 \dots i_n}$ ، وهذه القيمة تساوي ارتفاع القفزة للمتجه العشوائي X_n عند الموضع المذكور آنفاً، أي إنه لدينا:

$$p_{i_1 i_2 \dots i_n} := P(X_1 = x_{1i_1}, X_2 = x_{2i_2}, \dots, X_n = x_{ni_n}) \quad [5,42]$$

وهنا يجب أن تكون العلاقة الآتية محققة:

$$\sum_{i_1 \in I_1; i_2 \in I_2; \dots; i_n \in I_n} p_{i_1 i_2 \dots i_n} = 1 \quad [5,43]$$

٢- عندما يكون بعد المتجه $n \geq 3$ فإنه على سبيل التبسيط يُفضل استخدام الرموز i و j و k عوضاً عن i_1 و i_2 و i_3 على الترتيب، وفي هذه الحالة الخاصة يُفضل استخدام الأحرف X و Y و Z عوضاً عن X_1 و X_2 و X_3 على الترتيب، فعلى سبيل المثال يعرض لنا الشكل (٥, ٢٥) الآتي تمثيلاً بيانياً توضيح قيم الاحتمالات الكتلية لمتجه عشوائي متقطع $X_2 = (X, Y)$. حيث افترضنا أن $X = \{x_i ; i \in I \subseteq \mathbb{N}\}$ و $Y = \{y_j ; j \in J \subseteq \mathbb{N}\}$ هي مجموعة قيم المركبة X و Y على الترتيب، فنلاحظ أن الكتل الاحتمالية للمتجهات العشوائية المتقطعة كائنة في نقاط من الفضاء الثلاثي الأبعاد (أي على شكل نقطة بوزن يساوي كتلة الاحتمال) وترتفع عن المستوي XOY وفقاً لقيم هذه الكتل الاحتمالية.



الشكل (٥, ٢٥)

٢- من تعريف دالة التوزيع لمتجه عشوائي يمكننا من أجل كل $(x_1, x_2, \dots, x_n) \in \mathbb{R}^n$ أن نصيغ دالة توزيع متجه عشوائي متقطع \mathbb{X}_n من خلال العرض الآتي:

$$\begin{aligned} F_{\mathbb{X}_n}(x_1, x_2, \dots, x_n) &= P(X_1 < x_1, X_2 < x_2, \dots, X_n < x_n) \\ &= \sum_{i_1 \in I_1; x_{1i_1} < x_1} \sum_{i_2 \in I_2; x_{2i_2} < x_2} \dots \sum_{i_n \in I_n; x_{ni_n} < x_n} P(X_1 = x_{1i_1}, X_2 = x_{2i_2}, \dots, X_n = x_{ni_n}) \\ &= \sum_{i_1 \in I_1; x_{1i_1} < x_1} \sum_{i_2 \in I_2; x_{2i_2} < x_2} \dots \sum_{i_n \in I_n; x_{ni_n} < x_n} p_{i_1 i_2 \dots i_n} \end{aligned}$$

(٥, ٤, ٤, ٢) المتجهات العشوائية المستمرة Continuous Random Vectors

لقد لاحظنا سابقاً أن المتغيرات العشوائية المستمرة وحيدة البعد تكون مميزة من خلال دوال كثافتها الاحتمالية، وكذلك الأمر بالنسبة إلى المتجهات العشوائية المستمرة، والتعريف الآتي يبين لنا ذلك.

(٥, ٤, ٤, ٢, ١) تعريف (المتجه العشوائي المستمر)

ليكن \mathbb{X}_n متجهاً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فإذا وجدت دالة حقيقية f غير سالبة معرفة وكمولة على \mathbb{R}^n ، وبحيث إنه من أجل كل $(x_1, x_2, \dots, x_n) \in \mathbb{R}^n$ يكون لدينا ما يلي مُحققاً:

$$F_{\mathbb{X}_n}(x_1, x_2, \dots, x_n) = \int_{-\infty}^{x_1} \int_{-\infty}^{x_2} \dots \int_{-\infty}^{x_n} f(t_1, t_2, \dots, t_n) dt_1 dt_2 \dots dt_n$$

فعندئذ يُقال إن \mathbb{X}_n هو متجه عشوائي مستمر بدالة كثافة احتمالية f .

إن الدالة f والمحققة للشروط المذكورة أعلاه هي في الواقع كثافة رادون-نيكوديم من $P_{\mathbb{X}_n}$ (بالنسبة إلى قياس لوبيغ λ)، ولذلك يُرمز لها بـ $f_{\mathbb{X}_n}$ ، أي إنه لدينا:

$$F_{\mathbb{X}_n}(x_1, x_2, \dots, x_n) = \int_{-\infty}^{x_1} \int_{-\infty}^{x_2} \dots \int_{-\infty}^{x_n} f_{\mathbb{X}_n}(t_1, t_2, \dots, t_n) dt_1 dt_2 \dots dt_n \quad [5,45]$$

ويكون لدينا في هذه الحالة (نتج مباشرة من خواص دالة التوزيع الاحتمالية $F_{\mathbb{X}_n}$):

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f_{\mathbb{X}_n}(x_1, x_2, \dots, x_n) dx_1 dx_2 \dots dx_n = 1$$

(٥, ٤, ٤, ٢, ٢) ملاحظات

١- إنَّ الدالة $f_{\mathbb{X}_n}$ تدعى في بعض الأحيان **دالة الكثافة المشتركة** Joint Density Function لـ X_1, X_2, \dots, X_n ، ولذلك تُكتب بالشكل الآتي أيضاً:

$$f_{\mathbb{X}_n}(\vec{x}^n) = f_{X_1, X_2, \dots, X_n}(x_1, x_2, \dots, x_n) \quad ; \quad \vec{x}^n = (x_1, x_2, \dots, x_n)$$


٢- إذا كانت الدالة $f_{\mathbb{X}_n}$ مستمرة عند نقطة $\vec{x}^n = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$ ، فعندئذ ستكون دالة التوزيع $F_{\mathbb{X}_n}$ قابلة للاشتقاق الجزئي بالنسبة إلى كل مركبة x_k من مركبات المتجه \vec{x}^n ، ولدينا العلاقة الآتية مُحَقَّقة:

$$\frac{\partial^n}{\partial x_1 \partial x_2 \dots \partial x_n} F_{\mathbb{X}_n}(x_1, x_2, \dots, x_n) = f_{\mathbb{X}_n}(x_1, x_2, \dots, x_n) \quad [5,46]$$

وهذه العلاقة الأخيرة تبين أنه من أجل أية قيم حقيقية موجبة h_1, h_2, \dots, h_n و $0 < h_n$ ستكون العلاقة الآتية مُحَقَّقة أيضاً:

$$f_{\mathbb{X}_2}(x_1, x_2, \dots, x_n) = \lim_{\substack{h_1 \rightarrow 0 \\ h_2 \rightarrow 0 \\ \vdots \\ h_n \rightarrow 0}} \frac{P(x_1 \leq X_1 < x_1 + h_1, x_2 \leq X_2 < x_2 + h_2, \dots, x_n \leq X_n < x_n + h_n)}{h_1 \cdot h_2 \cdot \dots \cdot h_n}$$

من أجل الحالة الخاصة $n = 2$ يوضح لنا الشكل الآتي (٥, ٢٦) الرسم البياني الذي يُحدِّد قيمة الاحتمال العنصري $f_{\mathbb{X}_2}(x, y) dx dy$ لمتجه عشوائي مستمر $\mathbb{X}_2 = (X, Y)$ بدالة كثافة احتمالية $f_{\mathbb{X}_2}$ ، وقد أُعطي x تزايداً قدره dx في حين أُعطي y تزايداً قدره dy . حيث نلاحظ أنَّ $f_{\mathbb{X}_2}(x, y) dx dy$ التي تمثل الكثافة الاحتمالية للمتجه العشوائي المستمر $\mathbb{X}_2 = (X, Y)$ في المجال العنصري $[x, x + dx) \times [y, y + dy)$ لها شكل (أو حجم) كائن في فراغ ثلاثي الأبعاد.



الشكل (٥, ٢٦)

(٥, ٤, ٤, ٣) المتجهات العشوائية المختلطة Mixed Random Vectors

في الحقيقة تُعدّ المتجهات العشوائية المختلطة من أكثر المتجهات العشوائية ظهوراً وتكراراً في الدراسات التطبيقية والنظرية على

$$F_{\mathbb{X}_2}(x, y) = \int_{-\infty}^x \sum_{j; y_j < y} f_{\mathbb{X}_2}(t, y_j) dt \quad [5,50]$$

وهنا يمكن المبادلة بين التكامل والمجموع من أجل كل $(x, y) \in \mathbb{R}^2$ أيضاً.

(٤, ٤, ٤, ٥) أمثلة

١- ليكن $\mathbb{X}_2 = (X, Y)$ متجهاً عشوائياً متقطعاً فوق الفضاء الاحتمالي لتجربة إلقاء حجر نرد متوازن لمرة واحدة فقط، ولناخذ X و Y متغيرين عشوائيين فوق الفضاء الاحتمالي لهذه التجربة العشوائية ومعرّفين من أجل كل $\omega \in \Omega$ كما يلي:

$$X(\omega) = \omega \quad \& \quad Y(\omega) = 2\omega$$

ولنقم بتعيين دالة التوزيع الاحتمالية لهذا المتجه العشوائي، ومن ثمّ حسب قيمتها عند النقاط (1,1) و (3,7) و (8,15).

الحل: من معطيات المثال لدينا مركّباً الفضاء الاحتمالي $[\Omega, \mathcal{A}, P]$ للتجربة العشوائية المعطاة هي $\Omega = \mathbb{N}_6$ ولناخذ $\mathcal{A} = 2^\Omega$ فنجد أنّ $P(\{\omega\}) = \frac{1}{6}$ من أجل كل $\omega \in \Omega$ ، وكذلك لمجموعة قيم المتجه العشوائي \mathbb{X}_2 العرض الآتي:

$$G := \{(1, 2), (2, 4), (3, 6), (4, 8), (5, 10), (6, 12)\}$$

وبما أنّ حجر النرد متوازن فإنّ احتمالات الحوادث الابتدائية ستكون متساوية، ومن ثمّ ينتج لدينا ما يلي:

$$p_{ij} = P(X = x_i, Y = y_j) = \begin{cases} \frac{1}{6} & \text{for } j = 2i \\ 0 & \text{otherwise} \end{cases}$$

وأما دالة توزيع هذا المتجه العشوائي فلها العرض الآتي:

$$F_{\mathbb{X}_2}(x, y) = \sum_{i; x_i < x} \sum_{j; y_j < y} P(X = x_i, Y = y_j)$$

ومنه يكون لدينا على سبيل المثال:

$$F_{\mathbb{X}_2}(1, 1) = \sum_{i; i < 1} \sum_{j; j < 1} p_{ij} = 0$$

$$F_{\mathbb{X}_2}(3, 7) = \sum_{i; i < 3} \sum_{j; j < 7} p_{ij} = p_{12} + p_{24} = \frac{1}{6} + \frac{1}{6} = \frac{1}{3}$$

$$F_{\mathbb{X}_2}(8, 15) = \sum_{i; i < 8} \sum_{j; j < 15} p_{ij} = p_{12} + p_{24} + p_{36} + p_{48} + p_{510} + p_{612} = 1$$

علماً أنّ الاحتمالات p_{ij} ذات القيمة صفر تمّ تجاوزها وعدم كتابتها في الصيغ السابقة.

٢- ليكن $\mathbb{X}_2 = (X, Y)$ متجهاً عشوائياً مستمراً بدالة كثافة احتمالية معطاة من خلال العلاقة:

$$f_{\mathbb{X}_2}(x, y) = \begin{cases} \alpha x y & \text{for } (x, y) \in A \\ 0 & \text{otherwise} \end{cases}$$


علماً أنّ A هو المجال $(0, 1) \times (0, 1)$ ، وأما α فهو ثابت عددي مغاير للصفر، ولنقم بتعيين قيمة الثابت α ، ومن ثمّ تعيين دالة توزيع المتجه $\mathbb{X}_2 = (X, Y)$.

الحل: لنقم أولاً بتعيين قيمة الثابت α حيث نعلم أن:

$$1 = \lim_{\substack{x \rightarrow \infty \\ y \rightarrow \infty}} F_{X_2}(x, y) = \lim_{\substack{x \rightarrow \infty \\ y \rightarrow \infty}} \int_{-\infty}^x \int_{-\infty}^y f_{X_2}(x, y) dx dy = \alpha \cdot \int_0^1 \int_0^1 x \cdot y dx dy = \frac{\alpha}{4}$$

ومنه ينتج لدينا $\alpha = 4$.

وأما لتعيين دالة التوزيع F_{X_2} فإننا سنقوم بتجزئة الساحة \mathbb{R}^2 إلى خمسة قطاعات كما في الشكل الجانبي (٥، ٢٨)، فنجد ما يلي:



الشكل (٥، ٢٨)

أ- قيمة دالة التوزيع F_{X_2} عند كل نقطة (x, y) من القطاع (I) تساوي:

$$F_{X_2}(x, y) = \int_{-\infty}^x \int_{-\infty}^y f_{X_2}(t, u) dt du = 0$$

ب- قيمة دالة التوزيع F_{X_2} عند كل نقطة (x, y) من القطاع (II) تساوي:

$$F_{X_2}(x, y) = \int_{-\infty}^x \int_{-\infty}^y f_{X_2}(t, u) dt du = \int_0^x \int_0^y 4 \cdot t \cdot u dt du = x^2 \cdot y^2$$

ج- قيمة دالة التوزيع F_{X_2} عند كل نقطة (x, y) من القطاع (III) تساوي:

$$F_{X_2}(x, y) = \int_{-\infty}^x \int_{-\infty}^y f_{X_2}(t, u) dt du = \int_0^1 \int_0^y 4 \cdot t \cdot u dt du = y^2$$

د - قيمة دالة التوزيع F_{X_2} عند كل نقطة (x, y) من القطاع (IV) تساوي:

$$F_{X_2}(x, y) = \int_{-\infty}^x \int_{-\infty}^y f_{X_2}(t, u) dt du = \int_0^x \int_0^1 4 \cdot t \cdot u dt du = x^2$$

هـ- قيمة دالة التوزيع F_{X_2} عند كل نقطة (x, y) من القطاع (V) تساوي:

$$F_{X_2}(x, y) = \int_{-\infty}^x \int_{-\infty}^y f_{X_2}(t, u) dt du = \int_0^1 \int_0^1 4 \cdot t \cdot u dt du = 1$$

ومن ثم يكون لدالة التوزيع F_{X_2} العرض الآتي:

$$F_{X_2}(x, y) = \begin{cases} 0 & \text{for } x \leq 0 \quad \text{or} \quad y \leq 0 \\ x^2 y^2 & \text{for } 0 < x \leq 1 \quad \text{and} \quad 0 < y \leq 1 \\ y^2 & \text{for } x > 1 \quad \text{and} \quad 0 < y \leq 1 \\ x^2 & \text{for } 0 < x \leq 1 \quad \text{and} \quad y > 1 \\ 1 & \text{for } x > 1 \quad \text{and} \quad y > 1 \end{cases}$$

وبهذا ينتهي حل المثال المعطى.

(٥, ٥) التوزيعات الهامشية**Marginal Distributions**

يصادفنا في كثير من المسائل ضرورة التعامل مع دالة التوزيع الاحتمالية لإحدى مركبات (أو لأكثر من مركبة) متجه عشوائي $X_n = (X_1, X_2, \dots, X_n)$ ، وفي مثل هذه الحالات نكون معنيين باستخلاص صيغة دالة التوزيع لهذه المركبة (أو المركبات) من صيغة دالة التوزيع للمتجه العشوائي X_n . إن ما يُعرف باسم **التوزيعات الهامشية** تقوم بتنفيذ هذه المهمة.

(٥, ٥, ١) دوال الكثافة الهامشية Marginal Density Functions

من أجل توضيح مفهوم التوزيعات الهامشية وتبسيطها سنقوم بعرض دوال الكثافة الاحتمالية (أو الكتل الاحتمالية) الهامشية لمركبة واحدة، ومن ثم لمركبتين، وبناءً على تلك الدراسة يمكن استنتاج دوال الكثافة الاحتمالية (أو الكتل الاحتمالية) الهامشية لثلاث مركبات أو أكثر.

(٥, ٥, ١, ١) دالة الكثافة الهامشية لمركبة من مركبات متجه عشوائي

ليكن $X_n = (X_1, X_2, \dots, X_n)$ متجهاً عشوائياً بدالة كثافة احتمالية f_{X_n} ، علماً أن $2 \leq n$ عدد طبيعي، فعندئذ:

١- إذا كان المتجه العشوائي X_n متقطعاً بدالة كتلة احتمالية $p_{i_1 i_2 \dots i_n}$ فإن **دالة الكتلة الاحتمالية الهامشية للمركبة X_k** (علماً أن $N_n \ni k$ كفيي ولكن مثبت) تُعرف من خلال العلاقة الآتية:

$$f_{X_k}(x_k) \hat{=} p_{i_1 i_2 \dots i_{n-1} \bullet i_{k+1} \dots i_n} := \sum_{\substack{i_1 \in I_1 \& i_2 \in I_2 \& \dots \& i_{k-1} \in I_{k-1} \\ \& i_{k+1} \in I_{k+1} \& \dots \& i_n \in I_n}} p_{i_1 i_2 \dots i_n} \quad [5,51]$$

وذلك من أجل أي x_k من مجموعة قيم X_k ، علماً أن $p_{i_1 i_2 \dots i_n}$ معطى بالعلاقة [5,42].

٢- إذا كان المتجه العشوائي X_n مستمراً بدالة كثافة احتمالية f_{X_n} فإن **دالة الكثافة الهامشية للمركبة X_k** (مع $N_n \ni k$ كفيي ولكن مثبت) تُعرف من خلال العلاقة الآتية؛ وذلك من أجل كل $x_k \in \mathbb{R}$:

$$f_{X_k}(x_k) = \underbrace{\int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty}}_{(n-1) - \text{integrals}} f_{X_n}(x_1, x_2, \dots, x_n) dx_1 dx_2 \dots dx_{k-1} dx_{k+1} \dots dx_n \quad [5,52]$$

(٥, ٥, ١, ٢) دالة الكثافة الهامشية لمركبتين من مركبات متجه عشوائي

ليكن $X_n = (X_1, X_2, \dots, X_n)$ متجهاً عشوائياً بدالة كثافة احتمالية f_{X_n} ، علماً أن $2 \leq n$ عدد طبيعي، ولنأخذ $N_n \ni \ell, k$ مع $k \neq \ell$ كفيين ولكن مثبتين، فعندئذ:

١- إذا كان المتجه العشوائي X_n متقطعاً بدالة كتلة احتمالية $p_{i_1 i_2 \dots i_n}$ فإن الدالة الاحتمالية الكتلية الهامشية المشتركة للمركبتين X_ℓ, X_k (علماً أن العددين $N_n \ni \ell, k$ كفيين ولكنهما مثبتان مع $\ell \neq k$) تُعرف من خلال العلاقة الآتية:

$$f_{X_\ell, X_k}(x_\ell, x_k) \hat{=} p_{i_1 i_2 \dots i_{\ell-1} \bullet i_{\ell+1} \dots i_{k-1} \bullet i_{k+1} \dots i_n} = \sum_{\substack{i_1 \in I_1 \& i_2 \in I_2 \& \dots \& i_{\ell-1} \in I_{\ell-1} \& i_{\ell+1} \in I_{\ell+1} \\ \& \dots \& i_{k-1} \in I_{k-1} \& i_{k+1} \in I_{k+1} \& \dots \& i_n \in I_n}} p_{i_1 i_2 \dots i_n} \quad [5,53]$$

وذلك من أجل أي x_ℓ و x_k من مجموعة قيم X_ℓ و X_k على الترتيب.

٢- إذا كان المتجه العشوائي X_n مستمراً بدالة كثافة احتمالية f_{X_n} فإن دالة الكثافة الهامشية المشتركة للمركبتين X_k, X_ℓ مع $\ell \neq k$ تُعرف من خلال العلاقة الآتية وذلك من أجل كل $x_k, x_\ell \in \mathbb{R}$:

$$f_{X_\ell, X_k}(x_\ell, x_k) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f_{X_n}(x_1, x_2, \dots, x_n) dx_1 dx_2 \dots dx_{\ell-1} dx_{\ell+1} \dots dx_{k-1} dx_{k+1} \dots dx_n \quad [5,53]$$

(n-2)-integrals

وعلى هذا النحو نعمم هذه العلاقات على أي عدد من المركبات للمتجه X_n ، ولكن الصيغ قد لا تبدو بسيطة كما في الحالتين السابقتين.

(٥, ٥, ٢) دوال التوزيع الهامشية Marginal Distribution Functions

لنتنقل الآن إلى عروض دوال التوزيع الهامشية لمتجه عشوائي مستخدمين الأسلوب السابق في التوضيح.

(٥, ٥, ٢, ١) دوال التوزيع الهامشية لمركبة من مركبات متجه عشوائي

ليكن $X_n = (X_1, X_2, \dots, X_n)$ متجهاً عشوائياً بدالة كثافة احتمالية f_{X_n} ، فعندئذ:

١- إذا كان المتجه العشوائي X_n متقطعاً بدالة احتمالية كتلية $p_{i_1 i_2 \dots i_n}$ فإن دالة التوزيع الهامشية للمركبة X_k (علماً أن $N_n \ni k$ كفي ولكن مثبت) تُعرف من خلال العلاقة الآتية:

$$F_{X_k}(x) = \sum_{i_k; x_{i_k} < x} p_{i_1 i_2 \dots i_{k-1} \cdot i_{k+1} \dots i_n} \quad ; \forall x \in \mathbb{R} \quad [5,55]$$

٢- إذا كان المتجه العشوائي X_n مستمراً بدالة كثافة احتمالية f_{X_n} فإن دالة التوزيع الهامشية للمركبة X_k تُعرف من خلال العلاقة الآتية:

$$F_{X_k}(x) = \int_{-\infty}^x f_{X_k}(t) dt \quad ; \forall x \in \mathbb{R} \quad [5,56]$$

(٥, ٥, ٢, ٢) دالة التوزيع الهامشية لمركبتين من مركبات متجه عشوائي

ليكن $X_n = (X_1, X_2, \dots, X_n)$ متجهاً عشوائياً بدالة كثافة احتمالية f_{X_n} ، علماً أن $2 \leq n$ عدد طبيعي، ولنأخذ العددين $N_n \ni \ell, k$ كفيين ولكنهما مثبتان مع $\ell \neq k$ ، فعندئذ:

١- إذا كان المتجه العشوائي X_n متقطعاً بدالة احتمالية كتلية $p_{i_1 i_2 \dots i_n}$ فإن دالة التوزيع الهامشية المشتركة للمركبتين X_k, X_ℓ تُعرف لأجل كل $x_2, x_1 \in \mathbb{R}$ من خلال العلاقة الآتية:

$$F_{X_\ell, X_k}(x_1, x_2) = \sum_{i_\ell; x_{i_\ell} < x_1 \text{ و } i_k; x_{i_k} < x_2} p_{i_1 i_2 \dots i_{\ell-1} \cdot i_{\ell+1} \dots i_{k-1} \cdot i_{k+1} \dots i_n} \quad [5,57]$$

وذلك من أجل أي x_{i_k} و x_{i_ℓ} من مجموعة قيم X_k و X_ℓ على الترتيب.

٢- إذا كان المتجه العشوائي X_n مستمراً بدالة كثافة احتمالية f_{X_n} فإن دالة التوزيع الهامشية المشتركة للمركبتين X_k, X_ℓ مع $\ell \neq k$ تُعرف وذلك لأجل كل $x_2, x_1 \in \mathbb{R}$ من خلال العلاقة الآتية:

$$F_{X_\ell, X_k}(x_1, x_2) = \int_{-\infty}^{x_1} \int_{-\infty}^{x_2} f_{X_\ell, X_k}(t_1, t_2) dt_1 dt_2 \quad [5,58]$$

و على هذا النحو نعمم هذه العلاقات على أي عدد من المركبات للمتجه X_n ، ولكن الصيغ قد لا تبدو بسيطة كما في الحالتين

السابقتين.

(٥, ٥, ٢, ٣) ملاحظة

من أجل الحالة الخاصة $n = 2$ وعندما تكون مجموعة قيم المتجه العشوائي $\mathbb{X}_2 = (X, Y)$ منتهية وقليلة العدد نسبياً، فإنه يمكن حساب الاحتمالات الهامشية من خلال ما يُسمى بـ **جدول التوزيع الهامشي** لـ \mathbb{X}_2 ، فإذا كانت $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$ و $\mathbf{Y} = \{y_1, y_2, \dots, y_m\}$ هي مجموعة قيم المتغير العشوائي X و Y على الترتيب، فعندئذ يكون لجدول التوزيع الهامشي لـ \mathbb{X}_2 العرض الآتي:

الجدول (٥, ٦)

		قيم المتغير العشوائي X				Total
		x_1	x_2	x_n	
قيم المتغير العشوائي Y	y_1	p_{11}	p_{21}	p_{n1}	$p_{\bullet 1}$
	y_2	p_{12}	p_{22}	p_{n2}	$p_{\bullet 2}$
	\vdots	\vdots	\vdots	$\vdots \vdots \vdots$	\vdots	\vdots
	y_m	p_{1m}	p_{2m}	p_{nm}	$p_{\bullet m}$
Total		$p_{1\bullet}$	$p_{2\bullet}$	$p_{n\bullet}$	1

علماً أنه يجب ترتيب قيم X وكذلك Y في الجدول السابق بشكل متدرج من القيمة الأصغر إلى القيمة الأكبر، أي إنه لدينا في هذا الجدول $x_n > \dots > x_2 > x_1$ وكذلك $y_m > \dots > y_2 > y_1$.

(٥, ٥, ٢, ٤) أمثلة

١- ليكن $\mathbb{X}_2 = (X, Y)$ متجهاً عشوائياً متقطعاً بدالة احتمالية كتلية مُعطاة بالعلاقة الآتية:

$$p_{ij} = \begin{cases} \frac{7}{21} & \text{for } i = 1, 2 \text{ \& } j = 1 \\ \frac{4}{21} & \text{for } i = 1 \text{ \& } j = 2 \\ \frac{3}{21} & \text{for } i = 2 \text{ \& } j = 2 \end{cases}$$

ولنقم بتعيين التوزيعات الهامشية لكل من X و Y في توزيع المتجه \mathbb{X}_2 .**الحل:** من معطيات المثال نجد الآتي:

$$p_{\bullet 1} = p_{11} + p_{21} = \frac{7}{21} + \frac{7}{21} = \frac{14}{21} \quad \& \quad p_{\bullet 2} = p_{12} + p_{22} = \frac{4}{21} + \frac{3}{21} = \frac{7}{21}$$

$$p_{1\bullet} = p_{11} + p_{12} = \frac{7}{21} + \frac{4}{21} = \frac{11}{21} \quad \& \quad p_{2\bullet} = p_{21} + p_{22} = \frac{7}{21} + \frac{3}{21} = \frac{10}{21}$$

ومن ثم ينتج لدينا أن لدوال التوزيع الهامشية العروض الآتية:

$$F_X(x) = \sum_{i: x_i < x} p_{i\bullet} = \frac{11}{21} \mathbf{I}_{(0, 1]}(x) + \mathbf{I}_{(1, \infty)}(x)$$

$$F_Y(y) = \sum_{j: y_j < y} p_{\bullet j} = \frac{14}{21} I_{(0,1]}(y) + I_{(1,\infty)}(y)$$

٢- ليكن $\mathbb{X}_2 = (X, Y)$ متجهاً عشوائياً بدالة كثافة احتمالية مُعطاة على النحو الآتي:

$$f_{\mathbb{X}_2}(x, y) = \begin{cases} 4xy & \text{for } (x, y) \in [0, 1] \times [0, 1] \\ 0 & \text{otherwise} \end{cases}$$

حيث وجدنا في مثال سابق (المثال ٢ / من (٥, ٤, ٤, ٤)) أن دالة التوزيع لهذا المتجه العشوائي هي:

$$F_{\mathbb{X}_2}(x, y) = \begin{cases} 0 & \text{for } x \leq 0 \quad \text{or} \quad y \leq 0 \\ x^2 y^2 & \text{for } 0 < x \leq 1 \quad \text{and} \quad 0 < y \leq 1 \\ y^2 & \text{for } x > 1 \quad \text{and} \quad 0 < y \leq 1 \\ x^2 & \text{for } 0 < x \leq 1 \quad \text{and} \quad y > 1 \\ 1 & \text{for } x > 1 \quad \text{and} \quad y > 1 \end{cases}$$

عندئذ لتعيين الكثافتين الهامشيتين لهذا التوزيع نجد ما يلي:

أ- إن دالة الكثافة الهامشية لـ X تُعين بوساطة العلاقة الآتية:

$$f_X(x) = \int_{-\infty}^{\infty} f_{\mathbb{X}_2}(x, y) dy = \begin{cases} 2x & \text{for } 0 < x \leq 1 \\ 0 & \text{for } x \notin (0, 1] \end{cases}$$

ب- إن دالة الكثافة الهامشية لـ Y فإنها تُعين بوساطة العلاقة الآتية:

$$f_Y(y) = \int_{-\infty}^{\infty} f_{\mathbb{X}_2}(x, y) dx = \begin{cases} 2y & \text{for } 0 < y \leq 1 \\ 0 & \text{for } y \notin (0, 1] \end{cases}$$

وأما لتعيين دالتي التوزيع الهامشيتين لهذا التوزيع فإننا نجد بما يلي:

أ- إن دالة التوزيع الهامشية لـ X تُعين بوساطة العلاقة الآتية من أجل كل $x \in \mathbb{R}$:

$$F_X(x) = \int_{-\infty}^x f_X(t) dt = \begin{cases} 0 & \text{for } x \leq 0 \\ x^2 & \text{for } 0 < x \leq 1 \\ 1 & \text{for } x > 1 \end{cases}$$

ب- إن دالة التوزيع الهامشية لـ Y فإنها تُعين بوساطة العلاقة الآتية من أجل كل $y \in \mathbb{R}$:

$$F_Y(y) = \int_{-\infty}^y f_Y(t) dt = \begin{cases} 0 & \text{for } y \leq 0 \\ y^2 & \text{for } 0 < y \leq 1 \\ 1 & \text{for } y > 1 \end{cases}$$

وبهذا يتم الحل.

من التطبيقات المهمة للتوزيعات الهامشية ما يُعرف باسم **التوزيعات المركبة** Compound Distributions، وهي توزيعات لمتغيرات عشوائية لها دوال توزيع تابعة لمعلم، وهذه المعلم هي بدورها متغيرات عشوائية بتوزيع معين أيضاً، ولتوضيح دراسة هذا النوع من التوزيعات لنفترض أن X متغير عشوائي خاضع لتوزيع بمعلمة ξ ، وأن المعلمة ξ هي متغير عشوائي خاضع لتوزيع معلوم، فعندئذ لإيجاد توزيع X نأخذ متجهاً عشوائياً $\mathbb{X}_2 = (X, \xi)$ ، ومن ثم نوجد توزيع X من خلال حساب توزيعه الهامشي في توزيع المتجه (X, λ) ، والمثال الآتي يوضح لنا ذلك.

(٥, ٥, ٢, ٥) مثال

ليكن X متغيراً عشوائياً متقطعاً ويأخذ قيماً صحيحة غير سالبة من \mathbb{N}_0^n ، ومُميّزاً بالعلاقة الآتية:

$$P(X = k) = \binom{n}{k} p^k (1-p)^{n-k}$$

فعندئذ يُقال عن X إنه خاضع للتوزيع **الحداني** (أو **ذي الحدين**) Binomial Distribution بمعلمتين n و p (سنأتي على دراسته بشكل مفصل في الفصل القادم)، ولنفترض أن المعلمة n هي متغير عشوائي مستقل عن p وله توزيع مُميّز بالعلاقة الآتية:

$$P(n = \ell) = \frac{e^{-\lambda} \lambda^\ell}{\ell!}$$

علماً أن $0 < \lambda$ مثبت، فعندئذ يُقال عن n إنه خاضع لتوزيع بواسون Poisson Distribution بمعلمة λ (سنأتي على دراسته بشكل مفصل في الفصل القادم)، ولتعيين توزيع المتغير العشوائي X نأخذ المتجه العشوائي $\mathbb{X}_2 = (X, n)$ ، ومن ثم نقوم بحساب التوزيع الهامشي لـ X ، فنجد ما يلي:

$$P(X = k) = P(X = k, n = \mathbb{N}) = \sum_{\ell=0}^{\infty} P(X = k, n = \ell)$$

وباستخدام صيغ الاحتمالات الشرطية يصبح لدينا:

$$\begin{aligned} P(X = k) &= \sum_{\ell=0}^{\infty} P(X = k | n = \ell) \cdot P(n = \ell) = \sum_{\ell=0}^{\infty} \frac{e^{-\lambda} \lambda^\ell}{\ell!} \binom{\ell}{k} p^k (1-p)^{\ell-k} \\ &= \frac{e^{-\lambda} p^k}{k!} \sum_{\ell=k}^{\infty} \frac{\lambda^\ell}{(\ell-k)!} (1-p)^{\ell-k} = \frac{e^{-\lambda} p^k \lambda^k}{k!} \sum_{\ell=k}^{\infty} \frac{[\lambda(1-p)]^{\ell-k}}{(\ell-k)!} \\ &= \frac{e^{-\lambda} p^k \lambda^k}{k!} e^{\lambda(1-p)} = \frac{(\lambda p)^k}{k!} e^{-\lambda p} \end{aligned}$$

وبما أن الطرف الأيمن من العلاقة الأخيرة هي صيغة لمتغير عشوائي خاضع لتوزيع بواسون بمعلمة $\lambda \cdot p$ فإن ذلك يعني أن لـ X توزيع بواسوني بمعلمة $\lambda \cdot p$ ، وهذا التوزيع يُدعى **التوزيع الحداني المركب** Compound Binomial Distribution، وكتطبيق على هذا المثال سنفترض أن احتمال ولادة طفل ذكر في بلد ما يساوي 0.517، وأن X متغير عشوائي راصد لعدد الأطفال الذكور المولودين في أسرة (من هذا البلد) لديها n طفلاً، فعندئذ يكون لهذا المتغير العشوائي توزيع حداني بمعلمتين n و $p = 0.517$ ، أي إن احتمال أن يوجد k طفلاً من الذكور في أسرة ما لديها n طفلاً يساوي:

$$P(X = k) = \binom{n}{k} \cdot (0.517)^k (0.483)^{n-k}$$

وبفرض أن n متغير عشوائي بواسوني بمعلمة $0 < \lambda$ ، فعندئذ وفقاً لما توصلنا إليه في المثال السابق يكون لدينا:

$$P(X = k) = \frac{(\lambda \cdot p)^k}{k!} e^{-\lambda \cdot p} = \frac{(0.517\lambda)^k}{k!} e^{-0.517\lambda}$$

وهنا نلاحظ أن هذه العلاقة الأخيرة تتعلق بقيمة المعلمة λ التي يفترض أن تكون معلومة من أجل بلد ما، علماً أن قيمة هذه المعلمة تتغير من بلد لآخر.

(٥,٦) التوزيعات الشرطية

Conditional Distributions

من الدراسات المهمة في الاحتمالات تلك التوزيعات التي تُعرف باسم التوزيعات الشرطية، حيث تقوم هذه التوزيعات بتعيين توزيع مركبة أو أكثر من مركبات متجه عشوائي مشروطة بتحقق بعض المركبات المتبقية أو كلها.

(٥,٦,١) الاحتمالات الشرطية للمتغيرات العشوائية

لقد قدّمنا في فصل سابق مفهوم الاحتمال الشرطي لحادث A بالنسبة إلى حادث آخر B له احتمال موجب، ورمزنا لذلك بـ $P(A|B)$ ، ولأن سنقدم تمهيداً لمفهوم الاحتمال الشرطي لمتغير عشوائي X بالنسبة إلى متغير عشوائي آخر Y من خلال تقديم مفهوم الاحتمال الشرطي لمتغير عشوائي X بالنسبة إلى حادث $B \in \mathcal{A}$ علماً أن $0 < P(B)$. إن هذا المفهوم لا يختلف كثيراً عن مفهوم الاحتمال الشرطي $P(A|B)$ سوى أن الحادث الذي سيحل مكان A هو الحادث $\{\omega \in \Omega; X(\omega) \in D\}$ مع $D \in \mathcal{R}$.

(٥,٦,١,١) الاحتمال الشرطي لمتغير عشوائي بالنسبة إلى حادث

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ولناخذ $B \in \mathcal{A}$ مع $0 < P(B)$. عندئذ يُعرف **قانون التوزيع الشرطي** من X بالنسبة إلى (أو تحت شرط تحقق) الحادث B من خلال العلاقة الآتية:

$$P_{X|B}(D) \triangleq P(X \in D | B) = P_B(X^{-1}(D)) = \frac{P(X^{-1}(D) \cap B)}{P(B)} \quad [5,58]$$

وهذا يعني أن $P_{X|B} = P_B \circ X^{-1}$ (مبرر صحة هذا الاستخدام تجده في الملاحظة ٣/ من (١-٢-٤)). لاحظ هنا أنه في الحالة الخاصة عندما يكون لدينا $D = (-\infty, x)$ مع $x \in \mathbb{R}$ فإننا سنحصل على دالة التوزيع الشرطية من X بالنسبة إلى الحادث B التي تكتب بالشكل $F_{X|B}$ حيث لدينا:

$$\begin{aligned} F_{X|B}(x) &= P_{X|B}((-\infty, x)) = P_B(X^{-1}((-\infty, x))) \\ &= P(X \in (-\infty, x) | B) = P(X < x | B) = F_X(x | B) \end{aligned}$$

(٥,٦,١,٢) الاحتمال الشرطي لحادث بالنسبة إلى متغير عشوائي

لنوضح الآن مفهوم الاحتمال الشرطي لحادث B بالنسبة إلى متغير عشوائي X (أو تحت شرط تحقق الحادث $D \ni X$) حيث سنفترض على سبيل التبسيط والتوضيح أن هذا المتغير العشوائي متقطع.

لتكن X متغيراً عشوائياً متقطعاً بمجموعة قيم $X := \{x_i; i \in I\}$ ومعرّف فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، ولنضع $Z_i := X^{-1}(\{x_i\})$ من أجل أية قيمة $i \in I$ ، فنجد أن $Z_i \neq \emptyset$ من أجل كل $i \in I$ ، وأن الصف $\mathcal{Z}_X := \{Z_i; i \in I\}$ يشكل تجزئة للحادث الأكيد Ω (ولكنه لا يشكل جبراً فوق Ω)، ويمكننا أن نولد منه σ -جبر فوق Ω من خلال أخذ صف كل الاجتماعات المنتهية لعناصر من هذا الصف الذي يُعرف باسم **ال- σ جبر المولد بالمتغير العشوائي X** ، فلورمزنا لهذا ال- σ -جبر بالرمز \mathcal{A}_X فإنه سيكون لـ \mathcal{A}_X العرض الآتي:

$$\mathcal{A}_X := \left\{ \bigcup_{k \in K} Z_k; K \subseteq I \text{ with } K \text{ finite} \right\} \quad [5,59]$$

فإذا أخذنا $\mathcal{A} = 2^\Omega$ فعندئذ سيكون $\mathcal{A} \supseteq \mathcal{A}_X$.

بعد هذا التقديم يمكننا تقديم تعريف الاحتمال الشرطي لحادث B من \mathcal{A} بالنسبة إلى متغير عشوائي X على أنه متغير

عشوائي فوق الفضاء الاحتمالي $[\Omega, \mathcal{A}, P]$ نفسه، ومُعطى على النحو الآتي:

$$P(B | X)(\omega) = \begin{cases} \frac{P(B \cap Z_i)}{P(Z_i)} & \text{for } \omega \in Z_i \text{ with } P(Z_i) > 0 \\ 0 \leq \text{any value} \leq 1 & \text{for } \omega \in Z_i \text{ with } P(Z_i) = 0 \end{cases} \quad [5,60]$$

وفي هذه الحالة سيكون المتغير العشوائي $P(B | X)(\omega)$ متقطعاً أيضاً لأن عدد عناصر التجزئة \mathcal{Z} قابل للعد على الأكثر، وكذلك يلاحظ أنه من أجل كل $A \in \mathcal{A}_X$ تكون العلاقة الآتية محققة:

$$P(B | A) = \sum_{\substack{k \in K; Z_{i_k} \subseteq A \\ P(Z_{i_k}) > 0}} P(B \cap Z_{i_k}) \cdot P(Z_{i_k})$$

ويقابلها من أجل المتغيرات العشوائية المستمرة العلاقة الآتية:

$$P(B | A) = \int_A P(B \cap X)(\omega) P(d\omega) \quad [5,61-a]$$

وفي الحالة الخاصة عندما نأخذ $A = \Omega$ ينتج لدينا العلاقة الآتية:

$$P(B) = \int_{\Omega} P(B \cap X)(\omega) P(d\omega) \quad [5,61-b]$$

وهذه العلاقة الأخيرة تُعد تعميماً لصيغة الاحتمال التام التي مرّت معنا في الفصل السابق.

إن دراسة التوزيعات الشرطية للمتجهات العشوائية لا تخلو من الصعوبة عند التعامل مع متجهات عشوائية ذات بُعد أكبر من ثلاث (3)، وهذه الصعوبة تكمن بالدرجة الأولى في شكل الصياغات المستخدمة ودقة التعامل معها، وهذا ما سنلاحظه لاحقاً أثناء الدراسة في الفقرة القادمة، ولذلك سنقوم أولاً بتقديم الدراسة من أجل متجه عشوائي ثنائي البعد ومن ثم تعميم ذلك على متجه عشوائي ثلاثي البعد للحالة الموافقة للمتجهات العشوائية المتقطعة والمستمرة فقط، ولن نقوم بعرض الحالة الموافقة للمتجهات العشوائية المتقطعة ذات البعد النوني حيث يمكن لمن يود الاطلاع عليها الرجوع إلى المراجع ذات الصلة ومنها [64] المذكور في فهرس المراجع في نهاية هذا الكتاب.

إن فكرة التوزيعات الشرطية مبني على فهم المعنى للاحتمال الشرطي لمتغير عشوائي X بالنسبة (تحت شرط تحقق حادث متعلق بمتغير عشوائي آخر Y إلى متغير عشوائي Y ولذلك سنقوم أولاً بتوضيح معنى الاحتمال الشرطي لمتغير عشوائي X بالنسبة إلى متغير عشوائي Y ، وهنا سنفرّق بين الحالات التي يكون فيها المتجه العشوائي $X_2 = (X, Y)$ متقطعاً أو مستمراً وذلك على سبيل التوضيح والتبسيط في الدراسة، ومن ثم سنعمّم التعريف على الحالة $X_3 = (X_1, X_2, X_3)$ لأن عملية التعميم تتم بطريقة مماثلة.

(٥، ٦، ٢) التوزيعات الشرطية لمتجه عشوائي متقطع Conditional Distributions of a Discrete Random Vector

سنعالج فيما يلي الحالة الموافقة للمتجهات العشوائية المتقطعة فقط، وسنبداً بالدوال الاحتمالية الشرطية لمتجه عشوائي متقطع.

(٥، ٦، ٢، ١) الدوال الاحتمالية الشرطية لمتجه عشوائي متقطع

ليكن $X_2 = (X, Y)$ متجهاً عشوائياً متقطعاً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، ولنفترض أن $X = \{x_i; i \in I \subseteq \mathbb{N}\}$ و $Y = \{y_j; j \in J \subseteq \mathbb{N}\}$ هي مجموعة قيم X و Y على الترتيب، فعندئذ دالة الاحتمال (أو الكثافة الاحتمالية) الشرطية للمتغير العشوائي X عندما يأخذ القيمة x_i علماً أن المتغير العشوائي Y قد أخذ القيمة y_j باحتمال موجب تماماً تُعطى بالعلاقة الآتية:

$$f_{X|Y}(x_i | y_j) = P(X = x_i | Y = y_j) = \frac{P(X = x_i \wedge Y = y_j)}{P(Y = y_j)}$$

فإذا رمزنا بـ $p_{i|j} \triangleq P(X = x_i | Y = y_j)$ ، ونعلم أن:

$$P(Y = y_j) = \sum_{i \in I} P(X = x_i \wedge Y = y_j) = p_{\bullet j}$$

فإنه يمكننا أن نكتب:

$$p_{i|j} = \frac{p_{ij}}{p_{\bullet j}} \quad [5,62]$$

وبشكل مماثل نجد أن دالة الاحتمال الشرطية للمتغير العشوائي Y عندما يأخذ القيمة y_j علماً أن X قد أخذ القيمة x_i باحتمال موجب تماماً هي:

$$f_{Y|X}(y_j | x_i) = P(Y = y_j | X = x_i) = \frac{P(X = x_i \wedge Y = y_j)}{P(X = x_i)}$$

ولدينا:

$$P(X = x_i) = \sum_{j \in J} P(X = x_i \wedge Y = y_j) = p_{j\bullet}$$

فإنه يمكننا أن نكتب:

$$p_{j|i} = \frac{p_{ji}}{p_{j\bullet}} \quad [5,63]$$

الآن لنأخذ $X_3 = (X, Y, Z)$ متجهاً عشوائياً متقطعاً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، ولنفترض أن:

$$X = \{x_i; i \in I \subseteq \mathbb{N}\} \quad \& \quad Y = \{y_j; j \in J \subseteq \mathbb{N}\} \quad \& \quad Z = \{z_k; k \in K \subseteq \mathbb{N}\}$$

هي مجموعة قيم المتغيرات العشوائية X و Y و Z على الترتيب، فعندئذ دالة الاحتمال الشرطية للمتغير العشوائي X عندما يأخذ القيمة x_i علماً أن المتجه (Y, Z) قد أخذ القيمة $(y_j, z_k) \in Y \times Z$ باحتمال موجب تماماً تُعطى بالعلاقة الآتية:

$$f_{X|YZ}(x_i | y_j, z_k) = P(X = x_i | Y = y_j, Z = z_k) = \frac{P(X = x_i \wedge Y = y_j \wedge Z = z_k)}{P(Y = y_j \wedge Z = z_k)}$$

فلو رمزنا لـ $f_{X|YZ}(x_i | y_j, z_k)$ بالرمز $p_{i|jk}$ ، وكذلك وضعنا:

$$P(Y = y_j \wedge Z = z_k) = \sum_{i \in I} P(X = x_i, Y = y_j, Z = z_k) = p_{\bullet jk}$$

فإنه يمكننا أن نكتب:

$$p_{i|jk} = \frac{p_{ijk}}{p_{\bullet jk}} \quad [5,64-a]$$

وبشكل مماثل فلو رمزنا لـ $f_{Y|XZ}(y_j | x_i, z_k)$ و $f_{Z|XY}(z_k | x_i, y_j)$ بالرمز $p_{k|ij}$ و $p_{j|ik}$ على الترتيب، وكذلك وضعنا:

$$P(X = x_i, Z = z_k) = \sum_{j \in J} P(Y = y_j, X = x_i, Z = z_k) = p_{i\bullet k}$$

$$P(X = x_i, Y = y_j) = \sum_{k \in K} P(Z = z_k, X = x_i, Y = y_j) = p_{ij}.$$

فإنه يمكننا أن نكتب:

$$p_{j|i k} = \frac{p_{i j k}}{p_{i \bullet k}} \quad [5,64-b]$$

$$p_{k|i j} = \frac{p_{i j k}}{p_{i j \bullet}} \quad [5,64-c]$$

وَأما دالة الاحتمال الشرطية للمتجه (X, Y) عندما يأخذ القيمة $(x_i, y_j) \in X \times Y$ علماً أن المتغير العشوائي Z قد أخذ القيمة z_k باحتمال موجب تماماً، فإنها تُعطى بالعلاقة الآتية:

$$f_{XY|Z}(x_i, y_j | z_k) = P(X = x_i, Y = y_j | Z = z_k) = \frac{P(X = x_i \wedge Y = y_j \wedge Z = z_k)}{P(Z = z_k)}$$

فلو رمزنا لـ $f_{XY|Z}(x_i, y_j | z_k)$ بالرمز $p_{ij|k}$ ، وكذلك وضعنا:

$$P(Z = z_k) = \sum_{i \in I} \sum_{j \in J} P(X = x_i, Y = y_j, Z = z_k) = p_{\bullet \bullet k}$$

فإنه يمكننا أن نكتب:

$$p_{ij|k} = \frac{p_{i j k}}{p_{\bullet \bullet k}} \quad [5,65-a]$$

وبشكل مماثل فلو رمزنا لـ $f_{XZ|Y}(x_i, z_k | y_j)$ و $f_{YZ|X}(y_j, z_k | x_i)$ بالرمز $p_{ik|j}$ و $p_{jk|i}$ على الترتيب، ووضعنا بالتعريف ما يلي:

$$P(Y = y_j) = \sum_{i \in I} \sum_{k \in K} P(X = x_i, Z = z_k, Y = y_j) = p_{\bullet j}.$$

$$P(X = x_i) = \sum_{j \in J} \sum_{k \in K} P(Y = y_j, Z = z_k, X = x_i) = p_{i \bullet}.$$

فإنه يمكننا أن نكتب الآتي:

$$p_{ik|j} = \frac{p_{i j k}}{p_{\bullet j}} \quad [5,65-b]$$

$$p_{jk|i} = \frac{p_{i j k}}{p_{i \bullet}} \quad [5,65-c]$$

إن الصيغ الموافقة للحالة التي يكون فيها $X_n = (X_1, X_2, \dots, X_n)$ متجهاً عشوائياً متقطعاً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ تعمم بأسلوب مماثل، ولكن عملية الترميز، وصياغة العلاقات لن تكون بسيطة كما هو الحال لدى الحالتين السابقتين.

(٢, ٢, ٥) دالة التوزيع الشرطية لمتجه عشوائي متقطع

لنأخذ متجه عشوائي متقطع $X_3 = (X, Y, Z)$ فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، ولنفترض أن $X = \{x_i; i \in I \subseteq \mathbb{N}\}$ و $Y = \{y_j; j \in J \subseteq \mathbb{N}\}$ و $Z = \{z_k; k \in K \subseteq \mathbb{N}\}$ هي مجموعة قيم X و Y و Z على الترتيب، فعندئذ دالة التوزيع الشرطية للمتغير العشوائي X عندما يأخذ المتجه (Y, Z) قد أخذ القيمة $(y_j, z_k) \in Y \times Z$ باحتمال موجب تماماً

تُعطى بالعلاقة الآتية:

$$F_{X|Y,Z}(x | y_j, z_k) = P(X < x | Y = y_j, Z = z_k) = \sum_{i \in I; x_i < x} p_{i|jk} \quad [5,66-a]$$

وبالمثل نجد أن دالة التوزيع الشرطية للمتغير العشوائي Y عندما يأخذ المتجه (X, Z) القيمة $(x_i, z_k) \in X \times Z$ باحتمال موجب تماماً تُعطى بالعلاقة الآتية:

$$F_{Y|X,Z}(y | x_i, z_k) = P(Y < y | X = x_i, Z = z_k) = \sum_{j \in J; y_j < y} p_{j|ik} \quad [5,66-b]$$

وكذلك دالة التوزيع الشرطية للمتغير العشوائي Z عندما يأخذ المتجه (X, Y) القيمة $(x_i, y_j) \in X \times Y$ باحتمال موجب تماماً تُعطى بالعلاقة الآتية:

$$F_{Z|X,Y}(z | x_i, y_j) = P(Z < z | X = x_i, Y = y_j) = \sum_{k \in K; z_k < z} p_{k|ij} \quad [5,66-c]$$

أما دالة التوزيع الشرطية للمتجه (X, Y) عندما يأخذ المتغير العشوائي Z القيمة z_k باحتمال موجب تماماً فإنها تُعطى من خلال العلاقة الآتية وذلك من أجل كل $(x, y) \in \mathbb{R}^2$:

$$F_{XY|Z}(x, y | z_k) = P(X < x, Y < y | Z = z_k) = \sum_{\substack{i \in I; x_i < x \\ j \in J; y_j < y}} p_{ij|k} \quad [5,67-a]$$

وبالمثل نجد أن دالة التوزيع الشرطية للمتجه (X, Z) عندما يأخذ المتغير العشوائي Y القيمة y_j باحتمال موجب تماماً تُعطى من خلال العلاقة الآتية، وذلك من أجل كل $(x, z) \in \mathbb{R}^2$:

$$F_{XZ|Y}(x, z | y_j) = P(X < x, Z < z | Y = y_j) = \sum_{\substack{i \in I; x_i < x \\ k \in K; z_k < z}} p_{ik|j} \quad [5,66-b]$$

وكذلك دالة التوزيع الشرطية للمتجه (Y, Z) عندما يأخذ المتغير العشوائي X القيمة x_i باحتمال موجب تماماً فإنها تُعطى من خلال العلاقة الآتية؛ وذلك من أجل كل $(y, z) \in \mathbb{R}^2$:

$$F_{YZ|X}(y, z | x_i) = P(Y < y, Z < z | X = x_i) = \sum_{\substack{j \in J; y_j < y \\ k \in K; z_k < z}} p_{jk|i} \quad [5,66-c]$$

وأخيراً نجد أن دالة التوزيع الشرطية للمتغير العشوائي X علماً أن Y قد أخذت القيمة $y_j \in Y$ و $Z \in \mathbb{R}$ باحتمال موجب تماماً تُعطى من خلال العلاقة الآتية وذلك من أجل كل $x \in \mathbb{R}$:

$$F_{X|Y,Z}(x | y_j, \infty) = P(X < x | Y = y_j, Z \in \mathbb{R})$$

وبملاحظة أن الطرف الأيمن من العلاقة يمكن كتابته على الشكل الآتي:

$$P(X < x | Y = y_j, Z \in \mathbb{R}) = \sum_{k \in K} P(X < x | Y = y_j, Z = z_k)$$

فإنه يمكننا أن نكتب:

$$F_{X|Y,Z}(x | y_j, \infty) = \sum_{i \in I; x_i < x} p_{i|j}. \quad [5,67-a]$$

وتجدر الإشارة هنا إلى أن الطرف الأيسر من العلاقة الأخيرة هي كتابة اصطلاحية، ويجب ألا يفهم منها أن $z_k = \infty$ ، وإنما المقصود

منها هو أن $Z(\omega) \in \mathbb{R}$ من أجل كل $\omega \in \Omega$.

بالمثل نجد أن دالة التوزيع الشرطية للمتغير العشوائي Y علماً أن X قد أخذ القيمة $x_i \in \mathbf{X}$ و $Z \in \mathbb{R}$ باحتمال موجب تماماً تُعطى من خلال العلاقة الآتية؛ وذلك من أجل كل $y \in \mathbb{R}$:

$$F_{Y|XZ}(y | x_i, \infty) = P(Y < y | X = x_i, Z \in \mathbb{R}) = \sum_{j \in J; y_j < y} p_{j|i}. \quad [5,67-b]$$

وكذلك نجد أن دالة التوزيع الشرطية للمتغير العشوائي Z علماً أن X قد أخذ القيمة $x_i \in \mathbf{X}$ و $Y \in \mathbb{R}$ باحتمال موجب تماماً تُعطى من خلال العلاقة الآتية؛ وذلك من أجل كل $z \in \mathbb{R}$:

$$F_{Z|XY}(z | x_i, \infty) = P(Z < z | X = x_i, Y \in \mathbb{R}) = \sum_{k \in K; z_k < z} p_{k|i}. \quad [5,67-c]$$

وعلى هذا المنوال تُناقش بقية الحالات الممكنة بين X و Y و Z .

(٣، ٢، ٦، ٥) مثال

لدينا صندوق يحوي 36 كرة متماثلة تماماً، ومرقمة بالأرقام 1 وحتى 36. نخلط الكرات جيداً، ومن ثمَّ نسحب كرة من الصندوق دون إعادتها، وسنأخذ متجهاً عشوائياً $\mathbf{X}_2 = (X, Y)$ فوق الفضاء الاحتمالي لهذه التجربة العشوائية بحيث إن:

$$X(\omega) = \begin{cases} 0 & \text{for } \omega \text{ even} \\ 1 & \text{for } \omega \text{ odd} \end{cases} \quad \& \quad Y(\omega) = \begin{cases} 0 & \text{for } \omega \text{ divisible on } 3 \\ 1 & \text{otherwise} \end{cases}$$

ولنقم بتعيين التوزيعات الهامشية والشرطية لمركبات هذا المتجه العشوائي.

الحل: لنقم أولاً بتعيين التوزيعات الهامشية لكل من X و Y في توزيع $\mathbf{X}_2 = (X, Y)$ ، فنجد أن مجموعة قيم X هي $\mathbf{X} = \{x_1 = 0, x_2 = 1\}$ وكذلك مجموعة قيم Y هي $\mathbf{Y} = \{y_1 = 0, y_2 = 1\}$ ، ومن ثمَّ يكون لدينا ما يلي:

$$p_{11} = P(X = x_1, Y = y_1) = P(\{6, 12, 18, 24, 30, 36\}) = \frac{6}{36}$$

$$p_{12} = P(X = x_1, Y = y_2) = P(\{2, 4, 8, 10, 14, 16, 20, 22, 26, 28, 32, 34\}) = \frac{12}{36}$$

$$p_{21} = P(X = x_2, Y = y_1) = P(\{3, 9, 15, 21, 27, 33\}) = \frac{6}{36}$$

$$p_{22} = P(X = x_2, Y = y_2) = P(\{1, 5, 7, 11, 13, 17, 19, 23, 25, 29, 31, 35\}) = \frac{12}{36}$$

وأما التوزيعات الهامشية لهذا المتجه العشوائي فنجد أنها تساوي:

$$p_{1\bullet} = p_{11} + p_{12} = \frac{6}{36} + \frac{12}{36} = \frac{18}{36}$$

$$p_{2\bullet} = p_{21} + p_{22} = \frac{6}{36} + \frac{12}{36} = \frac{18}{36}$$

$$p_{\bullet 1} = p_{11} + p_{21} = \frac{6}{36} + \frac{6}{36} = \frac{12}{36}$$

$$p_{\bullet 2} = p_{12} + p_{22} = \frac{12}{36} + \frac{12}{36} = \frac{24}{36}$$

ومن ثمّ ينتج لدينا ما يلي:

$$F_X(x) = \sum_{i; x_i < x} p_{i\bullet} = \begin{cases} 0 & \text{for } x \leq 0 \\ p_{1\bullet} = \frac{1}{2} & \text{for } 0 < x \leq 1 \\ p_{1\bullet} + p_{2\bullet} = 1 & \text{for } x > 1 \end{cases}$$

وبالمثل نجد:

$$F_Y(y) = \sum_{j; y_j < y} p_{\bullet j} = \begin{cases} 0 & \text{for } y \leq 0 \\ p_{\bullet 1} = \frac{1}{3} & \text{for } 0 < y \leq 1 \\ p_{\bullet 1} + p_{\bullet 2} = 1 & \text{for } y > 1 \end{cases}$$

ولتعيين دالة التوزيع الشرطية لـ X عندما يكون الحادث $\{Y = y_2\}$ محققاً (أي تعيين $F_{X|Y}(x | y_2)$) نلاحظ أنّ:

$$P(Y = y_2) = \frac{24}{36} > 0$$

ومنه يكون لدينا:

$$F_{X|Y}(x | y_2) = \sum_{i; x_i < x} p_{i|2} = \sum_{i; x_i < x} \frac{p_{i2}}{p_{\bullet 2}} = \frac{1}{p_{\bullet 2}} \sum_{i; x_i < x} p_{i2} = \frac{36}{24} \sum_{i; x_i < x} p_{i2}$$

ومن العلاقة السابقة يكون لدينا:

$$F_{X|Y}(x | y_2) = \begin{cases} 0 & \text{for } x \leq 0 \\ \frac{36}{24} \frac{12}{36} = \frac{1}{2} & \text{for } 0 < x \leq 1 \\ 1 & \text{for } x > 1 \end{cases}$$

وأما تعيين بقية التوزيعات الشرطية لـ X و Y فتترك كتمرين للقارئ؛ لأنها تحسب بطريقة مماثلة لما سبق.

(٣, ٦, ٥) التوزيعات الشرطية لمتجه عشوائي مستمر Conditional Distributions of a Continuous Random Vector

في الواقع إنّ دراسة الكثافات الشرطية للمتجهات العشوائية المستمرة ليست بسيطة كما هو الحال للمتجهات العشوائية المتقطعة؛ لأنّ ذلك ينطوي على شروط عديدة ستعرف عليها في أثناء دراسة هذه الفقرة، ولكن سنقوم أولاً بتوضيح مفهوم الاحتمال الشرطي لمتغير عشوائي مستمر X بالنسبة إلى متغير عشوائي مستمر Y عندما يأخذ Y قيمة محدّدة y .

نعلم أنّ احتمال أن يأخذ متغير عشوائي مستمر قيمة محدّدة تماماً يساوي الصفر دوماً، ومن ثمّ يجب علينا توضيح معنى $P(X < x | Y = y)$ من أجل أي $x \in \mathbb{R}$. من أجل ذلك لنأخذ $\mathbb{X}_2 = (X, Y)$ متجهاً عشوائياً مستمراً بدالة كثافة احتمالية $f_{\mathbb{X}_2}(x, y)$ ، ولنفترض أنّه من أجل أي عدد حقيقي $0 < h$ وكل $y \in \mathbb{R}$ لدينا الحادث:

$$A := \{ \omega \in \Omega ; y \leq Y(\omega) < y + dy \} \quad [5,68]$$

محققاً باحتمال موجب تماماً، أي إنّ $P(A) > 0$ ، فعندئذ يمكننا أن نكتب الآتي:

$$P(X < x | y \leq Y < y + h) = \frac{P(X < x \wedge y \leq Y < y + h)}{P(y \leq Y < y + h)} = \frac{\int_y^{y+h} \int_{-\infty}^x f_{\mathbb{X}_2}(t, u) dt du}{\int_y^{y+h} \int_{-\infty}^{\infty} f_{\mathbb{X}_2}(t, u) dt du} \quad [5,69]$$

فلاحظ أنَّ الاحتمال في العلاقة الأخيرة ما هو إلاَّ دالة التوزيع الشرطي لـ X تحت شرط تحقق الحادث A المعطى بالعلاقة [5,68]، وعلاوة على ذلك فإنَّ الطرف الأيمن من العلاقة الأخيرة هي دالة مستمرة وغير متناقصة بـ x وتأخذ القيمة 0 عندما $x \rightarrow -\infty$ والقيمة 1 عندما $x \rightarrow +\infty$. لاحظ أنَّه حتى الآن ما زالت الصعوبة تكمن في إعطاء الاحتمال $P(X < x | Y = y)$ معنى محدد؛ ولذلك سنقتصر في دراستنا هنا على الحالة التي تكون فيها النهاية $\lim_{h \rightarrow 0} P(X < x | y \leq Y < y + h)$ موجودة، وكذلك سنفترض

$$\text{أنَّ دالة الكثافة الهامشية } f_Y(y) = \int_{-\infty}^{+\infty} f_{\mathbb{X}_2}(x, y) dx \text{ مستمرة وموجبة تماماً عند كل نقطة } y \in \mathbb{R}, \text{ أي إنَّ } 0 < f_Y(y).$$

الآن بالعودة إلى العلاقة [5,69] فإنَّنا نجد بتقسيم بسط ومقام الطرف الأيمن من تلك العلاقة على h ومن ثمَّ أخذ نهاية الطرفين عندما $h \rightarrow 0$ فيكون لدينا:

$$\lim_{h \rightarrow 0} P(X < x | y \leq Y < y + h) = \lim_{h \rightarrow 0} \frac{\frac{1}{h} \int_y^{y+h} \int_{-\infty}^x f_{\mathbb{X}_2}(t, u) dt du}{\frac{1}{h} \int_y^{y+h} \int_{-\infty}^{\infty} f_{\mathbb{X}_2}(t, u) dt du} = \frac{\int_{-\infty}^x f_{\mathbb{X}_2}(t, y) dt}{f_Y(y)}$$

ومن ثمَّ يمكننا أن نكتب:

$$P(X < x | y \leq Y < y + h) \approx \frac{\int_{t=-\infty}^x f_{\mathbb{X}_2}(t, y) dt}{f_Y(y)} = \int_{t=-\infty}^x \frac{f_{\mathbb{X}_2}(t, y)}{f_Y(y)} dt$$

فإذا رمزنا للنهاية $\lim_{h \rightarrow 0} P(X < x | y \leq Y < y + h)$ بـ $F_{X|Y}(x | y)$ ، فعندئذ سيكون لدينا:

$$F_{X|Y}(x | y) = \frac{\int_{-\infty}^x f_{\mathbb{X}_2}(t, y) dt}{f_Y(y)} \quad [5,70]$$

ومنه ينتج (بعد الأخذ بالحسبان الفرضيات التي قُدمت آنفاً) أنَّ $F_{X|Y}(x | y)$ هي دالة توزيع شرطية لمتغير عشوائي مستمر، ولو رمزنا لدالة الكثافة الاحتمالية الموافقة للدالة $F_{X|Y}(x | y)$ بالرمز $f_{X|Y}(x | y)$ ، فعندئذ يصبح لدينا:

$$f_{X|Y}(x | y) = \frac{f_{\mathbb{X}_2}(x, y)}{f_Y(y)} \quad ; \forall x \in \mathbb{R} \quad [5,71-a]$$

علماً أنَّ $f_Y(y)$ هي دالة الكثافة الهامشية لـ Y ، ومن ثمَّ يمكننا أن نكتب الآتي:

$$f_Y(y) \cdot F_{X|Y}(x | y) = \int_{-\infty}^x f_{\mathbb{X}_2}(x, y) dx \quad ; \forall y \in \mathbb{R}$$

بشكل مماثل لما سبق، وتحت الفرض أننا رمزنا للنهائية $\lim_{h \rightarrow 0} P(Y < y | x \leq X < x + h)$ بالرمز $F_{Y|X}(y|x)$ ، فإنه سيكون لدينا:

$$f_{Y|X}(y|x) = \frac{f_{X_2}(x, y)}{f_X(x)} \quad ; \forall y \in \mathbb{R} \quad [5,71-b]$$

ومن العلاقتين الأخيرتين ينتج لدينا ما يلي:

$$\int_{-\infty}^{+\infty} f_Y(y) F_{X|Y}(x|y) dy = \int_{-\infty}^x \int_{-\infty}^{+\infty} f_{X_2}(t, y) dy dt = F_X(x) \quad [5,72-a]$$

وكذلك:

$$\int_{-\infty}^{+\infty} f_X(x) F_{Y|X}(y|x) dx = \int_{-\infty}^y \int_{-\infty}^{+\infty} f_{X_2}(x, u) dx du = F_Y(y) \quad [5,72-b]$$

إن الصيغتين الأخيرتين [5,72-a] و [5,72-b] يُنظر إليهما على أنهما تعميم لصيغة دستور الاحتمال التام الواردة في الفصل الثاني، ولكن من أجل متغيرات عشوائية مستمرة.

تعميم:

من أجل الحالة $3 \leq n$ تُعمم بشكل مماثل تماماً لما سبق، فعلى سبيل المثال لو أخذنا $X_3 = (X, Y, Z)$ متجهاً عشوائياً فإنه سيكون لدينا:

$$\begin{aligned} P(X < x | Y = y, Z = z) &= \lim_{\substack{h \rightarrow 0 \\ k \rightarrow 0}} P(X < x | y < Y \leq y + h, z \leq Z < z + k) \\ &= \frac{1}{f_{Y,Z}(y, z)} \int_{-\infty}^x f_{X_3}(t, y, z) dt \end{aligned} \quad [5,73]$$

وهنا يجب الأخذ بالحسبان ضرورة استمرار الدالة $f_{X_3}(x, y, z)$ وكذلك $f_{Y,Z}(y, z)$ وأن يكون $0 < f_{Y,Z}(y, z)$ من أجل كل $(y, z) \in \mathbb{R}^2$. علماً أن $f_{Y,Z}(y, z)$ هي دالة الكثافة الهامشية لـ Y و Z .

(١، ٣، ٦، ٥) دوال الكثافة الشرطية لمتجه عشوائي مستمر

ليكن $X_3 = (X, Y, Z)$ متجهاً عشوائياً مستمراً بدالة كثافة احتمالية f_{X_3} ، ولنأخذ $x, y, z \in \mathbb{R}$ قيماً كيفية، فعندئذ:

١- بفرض أن الحادث الآتي:

$$A := \{\omega \in \Omega ; Y(\omega) = y, Z(\omega) = z\} \quad (1)$$

محقق الوقوع باحتمال موجب تماماً (أي إن $0 < P(A)$)، فإن دالة الكثافة الشرطية لـ X تحت الفرض بتحقق وقوع الحادث A تُعرف بالعلاقة الآتية:

$$f_{X|Y,Z}(x|y, z) = \frac{f_{X_3}(x, y, z)}{f_{Y,Z}(y, z)} \quad [5,74-a]$$

٢- بفرض أن كلا من الحادثين الآتيين:

$$B := \{\omega \in \Omega \mid Y(\omega) = y\} \quad (2)$$

$$C := \{\omega \in \Omega \mid Z(\omega) \in \mathbb{R}\} \quad (3)$$

مُحقق الوقوع باحتمال موجب تماماً (أي إنَّ $0 < P(B)$ و $0 < P(C)$)، فإنَّ دالة الكثافة الشرطية لـ X وتحت الفرض بتحقق وقوع الحادثين B و C تُعرَّف بالعلاقة الآتية:

$$f_{X|Y,Z}(x|y, \infty) = \frac{f_{X,Y}(x, y)}{f_Y(y)} \quad [5,74-b]$$

٣- بفرض أنَّ الحادث الآتي:

$$D := \{\omega \in \Omega \mid Z(\omega) = z\} \quad (4)$$

مُحقق الوقوع باحتمال موجب تماماً (أي إنَّ $0 < P(D)$)، فإنَّ دالة الكثافة الشرطية لـ X و Y وتحت الفرض بتحقق وقوع الحادث D تُعرَّف بالعلاقة الآتية:

$$f_{X,Y|Z}(x, y|z) = \frac{f_{X_3}(x, y, z)}{f_Z(z)} \quad [5,75-a]$$

(٢، ٣، ٦، ٥) دوال التوزيع الشرطية لمتجه عشوائي مستمر

ليكن $X_3 = (X, Y, Z)$ متجهاً عشوائياً مستمراً بدالة كثافة احتمالية f_{X_3} ، ولنأخذ $x, y, z \in \mathbb{R}$ قيماً كيفية، فعندئذ:
١- تحت الفرض بتحقق وقوع الحادث A المعطى بالعلاقة (1) وكان $0 < P(A)$ فإنَّ دالة التوزيع الشرطية لـ X وتحت الفرض بتحقق وقوع الحادث A تُعطى من أجل كل $x \in \mathbb{R}$ بوساطة العلاقة الآتية:

$$F_{X|Y,Z}(x|y, z) = P(X < x | A)$$

وتُكتب عادة على النحو الآتي:

$$F_{X|Y,Z}(x|y, z) = \int_{-\infty}^x f_{X|Y,Z}(t|y, z) dt$$

٢- تحت الفرض بتحقق وقوع الحادثين B و C المعطيين بالعلاقين (2) و (3) وكان $0 < P(B)$ وكذلك $0 < P(C)$ فإنَّ دالة التوزيع الشرطية لـ X وتحت الفرض بتحقق وقوع الحادثين B و C تُعطى من أجل كل $x \in \mathbb{R}$ بوساطة العلاقة الآتية:

$$F_{X|Y,Z}(x|y, z) = P(X < x | B, C)$$

وتُكتب عادة على النحو الآتي:

$$F_{X|Y,Z}(x|y, \infty) = \int_{-\infty}^x f_{X|Y,Z}(t|y, \infty) dt$$

٣- تحت الفرض بتحقق وقوع الحادث D المعطى بالعلاقة (4) وكان $0 < P(D)$ فإنَّ دالة التوزيع الشرطية لـ X و Y وتحت الفرض بتحقق وقوع الحادث D تُعطى من أجل كل $x, y \in \mathbb{R}$ بوساطة العلاقة الآتية:

$$F_{X,Y|Z}(x, y|z) = P(X < x, Y < y | D)$$

وتُكتب عادة على النحو الآتي:

$$F_{X,Y|Z}(x, y|z) = \int_{-\infty}^x \int_{-\infty}^y f_{X,Y|Z}(t, u|z) dt du$$

(٥, ٦, ٣, ٣) أمثلة

١- بالعودة إلى المثال / ٢ / من (٥, ٥, ٢, ٤) سنبحث في تعيين دالة التوزيع الهامشية للمتغير العشوائي X في توزيع المتجه العشوائي $\mathbb{X}_2 = (X, Y)$ ، وكذلك تعيين دالة التوزيع الشرطية للمتغير العشوائي X عندما يكون الحادث $\{Y = y\}$ محققاً باحتمال موجب تماماً.

الحل: لنقم أولاً بحساب دالة الكثافة الهامشية للمتغير العشوائي X ، فنجد لها العرض الآتي من أجل كل $x \in \mathbb{R}$:

$$f_X(x) = \int_{-\infty}^{\infty} f_{\mathbb{X}_2}(x, y) dy = \begin{cases} 0 & \text{for } x \leq 0 \text{ or } x \geq 1 \\ 2x & \text{for } 0 < x < 1 \end{cases}$$

ومن ثم يكون لدالة التوزيع الهامشية لـ X في توزيع \mathbb{X}_2 العرض الآتي:

$$F_X(x) = \int_{-\infty}^x f_X(t) dt = x^2 \cdot \mathbf{I}_{(0,1)}(x) + \mathbf{I}_{[1, \infty)}(x)$$

الآن لتعيين دالة التوزيع الشرطية لـ X عندما يكون الحادث $\{Y = y\}$ محققاً باحتمال موجب تماماً سنقوم أولاً بتعيين دالة الكثافة الشرطية لـ X عندما يكون الحادث $\{Y = y\}$ محققاً باحتمال موجب تماماً، فنجد من أجل أي $y \in (0, 1)$ ما يلي:

$$f_{X|Y}(x|y) = \begin{cases} 2x & \text{for } 0 < x < 1 \\ 0 & \text{otherwise} \end{cases}$$

وأما من أجل قيم y التي لا تنتمي إلى الفترة $(0, 1)$ سيكون لدينا $f_Y(y) = 0$ ، ومن ثم يصبح لدينا في هذه الحالة:

$$f_{X|Y}(x, y) = 0$$

وهكذا يكون للدالة $F_{X|Y}(x|y)$ العرض الآتي:


$$F_{X|Y}(x|y) = \int_{-\infty}^x f_{X|Y}(t|y) dt = x^2 \cdot \mathbf{I}_{(0,1)}(x) + \mathbf{I}_{[1, \infty)}(x) \quad ; \forall y \in (0, 1)$$

علماً أنه من أجل قيم y التي لا تنتمي إلى الفترة $(0, 1)$ سيكون لدينا $F_{X|Y}(x, y) = 0$ ، وبذلك يكون قد تم المطلوب.

٢- ليكن $\mathbb{X}_2 = (X, Y)$ متجهاً عشوائياً مستمراً بدالة كثافة احتمالية

$$f_{\mathbb{X}_2}(x, y) = \begin{cases} \alpha x y & \text{for } (x, y) \in D \\ 0 & \text{otherwise} \end{cases}$$

علماً أن D هي الساحة المحددة من خلال العلاقات $x = 0$ و $y = 0$ و $x + y = 1$ ، وأما α فهو ثابت مغاير للصفر يُطلب تعيينه، ولنقم بتعيين $f_{X|Y}(x|y)$ ومن ثم $F_X(x)$ ، وأخيراً تعيين $F_{X|Y}(x, y)$.



الشكل (٥, ٢٩)

الحل: من أجل ذلك لنقم بتجزئة الساحة \mathbb{R}^2 إلى ساحات جزئية كما هو موضح في الشكل الجانبي (٥, ٢٩)، حيث نلاحظ أن الساحة D ممثلة بالقطاع (2)، ومن ثم لحساب الثابت α لدينا:

$$1 = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f_{\mathbb{X}_2}(x, y) dx dy = \alpha \int_0^1 dy \int_0^{1-y} x y dx = \frac{\alpha}{24}$$

ومنه ينتج أن $\alpha = 24$ ، علماً أن التكاملات التي قيمها معدومة لم تكتب في الصيغة الأخيرة.

الآن لتعيين دالة توزيع X_2 نجد ما يلي:

أ- من أجل كل (x, y) من الساحة رقم (1) لدينا:

$$F_{X_2}(x, y) = \int_{-\infty}^x \int_{-\infty}^y f_{X_2}(t, u) dt du = 0$$

ب- من أجل كل (x, y) من الساحة رقم (2) لدينا:

$$F_{X_2}(x, y) = \int_{-\infty}^x \int_{-\infty}^y f_{X_2}(t, u) dt du = 6x^2y^2$$

ج- من أجل كل (x, y) من الساحة رقم (3) لدينا:

$$F_{X_2}(x, y) = \int_{-\infty}^x \int_{-\infty}^y f_{X_2}(t, u) dt du = 1 - \left[\int_x^1 \int_0^{1-x} f_{X_2}(t, u) dt du + \int_y^1 \int_0^{1-y} f_{X_2}(t, u) dt du \right]$$

وبالتعويض عن $f_{X_2}(t, u)$ بما يساويها ومن ثم المكاملة نحصل على الصيغة الآتية لدالة التوزيع $F_{X_2}(x, y)$ على هذه الساحة:

$$F_{X_2}(x, y) = 1 - 24 \left[\int_x^1 t dt \int_0^{1-x} u du + \int_y^1 u du \int_0^{1-y} t dt \right] = 1 - 6 \left[(1-x^2) \cdot (1-x)^2 + (1-y^2) \cdot (1-y)^2 \right]$$

د- من أجل كل (x, y) من الساحة رقم (4) لدينا:

$$F_{X_2}(x, y) = \int_{-\infty}^x \int_{-\infty}^y f_{X_2}(t, u) dt du = 24 \int_0^y u du \int_0^{1-y} t dt = 6y^2 - 8y^3 + 3y^4$$

هـ- من أجل كل (x, y) من الساحة رقم (5) لدينا:

$$F_{X_2}(x, y) = \int_{-\infty}^x \int_{-\infty}^y f_{X_2}(t, u) dt du = 24 \int_0^x t dt \int_0^{1-x} u dt = 6x^2 - 8x^3 + 3x^4$$

و- من أجل كل (x, y) من الساحة رقم (6) لدينا:

$$F_{X_2}(x, y) = \int_{-\infty}^x \int_{-\infty}^y f_{X_2}(t, u) dt du = 24 \int_0^1 u du \int_0^{1-y} t dt = 1$$

ومن ثم ينتج لدينا أن لدالة التوزيع $F_{X_2}(x, y)$ العرض الآتي:

$$F_{X_2}(x, y) = \begin{cases} 0 & \text{for } x \leq 0 \text{ or } y \leq 0 \\ 6x^2y^2 & \text{for } 0 < x \leq 1 \text{ and } 0 < y \leq 1 \text{ with } x + y \leq 1 \\ 1 - 6 \left[(1-x^2) \cdot (1-x)^2 + (1-y^2) \cdot (1-y)^2 \right] & \text{for } 0 < x \leq 1 \text{ and } 0 < y \leq 1 \text{ with } x + y > 1 \\ 6y^2 - 8y^3 + 3y^4 & \text{for } x > 1 \text{ and } 0 < y \leq 1 \\ 6x^2 - 8x^3 + 3x^4 & \text{for } 0 < x \leq 1 \text{ and } y > 1 \\ 1 & \text{for } x > 1 \text{ and } y > 1 \end{cases}$$

والآن لتعيين دالة التوزيع الهامشية لـ X يجب علينا تعيين دالة كثافته الهامشية $f_X(x)$ أولاً حيث لدينا من أجل كل $x \in \mathbb{R}$ ما يلي:

$$f_X(x) = \int_{-\infty}^{\infty} f_{X_2}(x, y) dy = \begin{cases} 12x(1-x)^2 & \text{for } 0 < x \leq 1 \\ 0 & \text{otherwise} \end{cases}$$

ومن ثم يكون لدالة التوزيع الهامشية لـ X العرض الآتي:

$$F_X(x) = \int_{-\infty}^x f_X(t) dt = \begin{cases} 0 & \text{for } x \leq 0 \\ 6x^2 - 8x^3 + 3x^4 & \text{for } 0 < x \leq 1 \\ 1 & \text{for } x > 1 \end{cases}$$

أخيراً لتعيين دالة التوزيع الشرطية لـ X عندما يكون الحادث $\{Y = y\}$ مُحَقَّقاً باحتمال موجب تماماً علينا أولاً تعيين الكثافة الشرطية لـ X ، فنجد ما يلي:

أ - من أجل $0 < y \leq 1$ لدينا:

$$f_{X|Y}(x|y) = \frac{f_{X_2}(x, y)}{f_Y(y)} = \begin{cases} \frac{2x}{(1-y)^2} & \text{for } 0 < x \leq 1 \text{ and } x+y \leq 1 \\ 0 & \text{otherwise} \end{cases}$$

وأما من أجل قيم y التي لا تنتمي إلى الفترة $(0, 1]$ سيكون لدينا $f_{X|Y}(x|y) = 0$ ، ومن ثم ينتج أن لدالة التوزيع الشرطية لـ X العرض الآتي من أجل كل $y \in (0, 1]$:

$$F_{X|Y}(x|y) = \int_{-\infty}^x f_{X|Y}(t|y) dt = \begin{cases} 0 & \text{for } x \leq 0 \\ \frac{x^2}{(1-y)^2} & \text{for } 0 < x \leq 1-y \\ 1 & \text{for } x > 1-y \end{cases}$$

وبذلك يكون الحل قد اكتمل.

هذا ما تيسر تقديمه من أجل الجزء النظري والتطبيقي لهذا الفصل

تمارين الفصل الخامس

١- ليكن $[\Omega, \mathcal{A}, P]$ الفضاء الاحتمالي لتجربة إلقاء حجر نرد متمايزين ومتوازنين لمرة واحدة، وليكن X تطبيقاً حقيقياً معرفاً على Ω كما يلي:

$$X(\omega) = X((i, j)) := \begin{cases} +1 & \text{for } i + j \geq 10 \\ 0 & \text{for } 1 \leq i < 3 \text{ and } j \in \{1, \dots, 6\} \\ -1 & \text{for } i = 3 \text{ and } j \leq 3 \\ -5 & \text{otherwise} \end{cases}$$

والمطلوب ما يلي:

أ- أثبت أن X هو متغير عشوائي فوق $[\Omega, \mathcal{A}, P]$.

ب- عين دالة توزيع X وارسمها.

ج- احسب الاحتمال $P(-3 < X \leq 0)$.

د- هل يبقى X متغيراً عشوائياً فوق $[\Omega, \mathcal{A}, P]$ إذا كان حجر النرد غير متمايزين؟

٢- لدى عملية تصنيع منتج من نوع محدد نقوم بسحب عشوائي لمجموعات كل منها مكونة من ثلاثة عناصر منتجة؛ وذلك بغية تفتيشها والتحقق من أنها تحقق المواصفات المطلوبة، فإذا كنا ننظر إلى حصولنا على مكون معيب أنه نجاح Success، وبفرض أننا سحبنا 8 مجموعات وكانت نتائجها كما في الجدول الآتي (علماً أن الحرف F يعني الفشل Failure):

نتائج السحب	SSS	SFS	SSF	FSS	SFF	FSF	FFS	FFF
-------------	-----	-----	-----	-----	-----	-----	-----	-----

فلو كان X تطبيقاً راصداً لعدد مرات النجاح في السحوبات جميعاً، فعندئذ:

أ- أثبت أن التطبيق X هو متغير عشوائي فوق الفضاء الاحتمالي لإنتاج المصنع (يطلب تعيينه).

ب- مثل هذا المتغير العشوائي بيانياً.

ج- عين دالة توزيعه الاحتمالية.

٣- ليكن X متغيراً عشوائياً مستمراً بدالة كثافة احتمالية $f_X(x)$ معطاة من خلال المعادلة الآتية:

$$f_X(x) = \alpha x^2 \mathbf{I}_{[0,1]}(x) \quad ; \forall x \in \mathbb{R}$$

والمطلوب ما يلي:

أ- عين قيمة الثابت α ، ومن ثم احسب الاحتمال $P(X \leq 0.5)$.

ب- عين دالة توزيع X .

٤- لتكن $X, Y, X_1, X_2, \dots, X_n, \dots$ متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ أثبت (متن المبرهنة (٥، ١، ٤، ٢)) أن الدالة Z في الصيغ الآتية هي متغير عشوائي فوق $[\Omega, \mathcal{A}, P]$ أيضاً:

- a) $Z = |X|$ & b) $Z = aX + b$; $a, b \in \mathbb{R}$ and $a \neq 0$
c) $Z = X \pm Y$ & d) $Z = X \cdot Y$
e) $Z = \frac{X}{Y}$; $Y(\omega) \neq 0$ for all $\omega \in \Omega$ & f) $Z = \max \{X_i, X_j\}$; $i, j \in \mathbb{N}, i \neq j$

$$\begin{aligned} \text{g) } Z &= \min \{X_i, X_j\} ; i, j \in \mathbb{N}, i \neq j & \text{h) } Z &= \sup \{X_n ; n \in \mathbb{N}\} \\ \text{i) } Z &= \inf \{X_n ; n \in \mathbb{N}\} & \text{j) } Z &= \overline{\lim}_{n \rightarrow \infty} X_n = \limsup_{n \rightarrow \infty} X_n \\ \text{k) } Z &= \lim_{n \rightarrow \infty} X_n = \liminf_{n \rightarrow \infty} X_n & \text{l) } Z &= \lim_{n \rightarrow \infty} X_n \end{aligned}$$

٥- لتكن لدينا الدالة الآتية:

$$f(x) = c \binom{3}{x} \binom{4}{4-x} ; x = 0, 1, 2, 3$$

والمطلوب تعيين قيمة الثابت c بحيث تصبح هذه الدالة هي دالة الاحتمالات الكتلية لمتغير عشوائي X .

٦- ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ بدالة توزيع احتمالية F_X ، والمطلوب تعيين دالة توزيع المتغير العشوائي Y في كل من الحالات الآتية:

$$\begin{aligned} \text{a) } Y &:= aX + b ; a, b \in \mathbb{R}, a \neq 0 & \text{b) } Y &:= |X| \\ \text{c) } Y &:= X^2 & \text{d) } Z &:= \frac{1}{X} ; X(\omega) \neq 0, \forall \omega \in \Omega \end{aligned}$$

٧- ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ بدالة توزيع احتمالية F_X ، والمطلوب إثبات أن F_X هي متغير عشوائي أيضاً، ومن ثمّ تعيين دالة توزيعها، أي تعيين صيغة الدالة F_{F_X} .

٨- ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتمالي معطى على النحو الآتي:

$$\Omega = [0, \infty) \times [0, \infty) \quad \& \quad \mathcal{A} = \mathbb{R}^2 \cap \{[0, \infty) \times [0, \infty)\}$$

$$\text{and } P(A) := \int_A e^{-(x_1+x_2)} dx_1 dx_2 ; \forall A \in \mathcal{A}$$

وليكن X تطبيقاً من Ω في \mathbb{R} مُعرّفاً بالعلاقة $X((x_1, x_2)) := x_1 + x_2$ ، والمطلوب إثبات أن X هو متغير عشوائي فوق $[\Omega, \mathcal{A}, P]$.

٩- ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتمالي، علماً أن:

$$\Omega = \mathbb{N}_6 \quad \& \quad \mathcal{A} = 2^\Omega \quad \& \quad P(\{\omega\}) = \frac{1}{6}$$

ولنأخذ $\mathbb{X}_2 = (X, Y)$ متجهاً عشوائياً متقطعاً فوق $[\Omega, \mathcal{A}, P]$ بحيث إنه من أجل كل $\omega \in \Omega$ لدينا:

$$X(\omega) = \omega \quad \& \quad Y(\omega) = 5\omega + 1$$

والمطلوب تعيين دالة التوزيع للمتجه العشوائي \mathbb{X}_2 .

١٠- ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتمالي، علماً أن:

$$\Omega = \mathbb{N}_6 \quad \& \quad \mathcal{A} = 2^\Omega \quad \& \quad P(\{\omega\}) = \frac{1}{6}$$

ولنأخذ $\mathbb{X}_3 = (X, Y, Z)$ متجهاً عشوائياً متقطعاً فوق $[\Omega, \mathcal{A}, P]$ وبحيث إنه من أجل كل $\omega \in \Omega$ لدينا:

$$X(\omega) = \omega \quad \& \quad Y(\omega) = [X(\omega)]^2 \quad \& \quad Z(\omega) = [X(\omega)]^3(\omega) ; \forall \omega \in \Omega$$

والمطلوب تعيين دالة التوزيع للمتجه العشوائي \mathbb{X}_3 .

١١- لدينا صندوق يحوي 24 كرة متماثلة تماماً ومُرَقَّمة بالأرقام 1 وحتى 24. نُخلط الكرات جيداً ومن ثم تُسحب كرة من الصندوق دون إعادتها، وليكن $\mathbb{X}_3 = (X, Y, Z)$ متَّجهاً عشوائياً فوق الفضاء الاحتمالي لهذه التجربة العشوائية بحيث إن:

$$X(\omega) = \begin{cases} 0 & \text{for } \omega \text{ even} \\ 1 & \text{for } \omega \text{ odd} \end{cases}$$

$$Y(\omega) = \begin{cases} 0 & \text{for } \omega \text{ divisible on } 3 \\ 1 & \text{otherwise} \end{cases}$$

$$Z(\omega) = \begin{cases} 0 & \text{for } \omega \leq 12 \\ 1 & \text{for } \omega > 12 \end{cases}$$

والمطلوب ما يلي:

أ- تعيين دالة توزيع هذا المتَّجه العشوائي.

ب- تعيين التوزيعات الهامشية لمركبات هذا المتَّجه العشوائي.

ج- تعيين التوزيعات الشرطية $P_{i|j|k}$ و $P_{i|j|k}$ من أجل $i=1$ و $j=2$ وأخيراً $k=1$.

١٢- ليكن $\mathbb{X}_2 = (X, Y)$ متَّجهاً عشوائياً مستمراً بدالة كثافة احتمالية مُعطاة من خلال العلاقة الآتية:

$$f_{\mathbb{X}_2}(x, y) = \begin{cases} \alpha(x \cdot y) & \text{for } (x, y) \in B \\ 0 & \text{otherwise} \end{cases}$$

علماً أنَّ $\alpha \neq 0$ ثابت عددي، والمطلوب ما يلي:

أ- تعيين قيمة الثابت α .

ب- تعيين دالة توزيع المتَّجه العشوائي \mathbb{X}_2 في كل من الحالتين الآتيتين:

- إذا كانت المجموعة B هي المجال $(0, 1) \times (0, 1)$.

- إذا كانت المجموعة B هي الساحة المحددة بالعلاقات $x=0$ و $y=0$ و $x+y=1$.

١٣- ليكن $\mathbb{X}_2 = (X, Y)$ متَّجهاً عشوائياً مختلطاً فيه X متغير عشوائي مستمر بدالة كثافة احتمالية:

$$f_X(x) = \lambda e^{-\lambda x} \cdot \mathbf{I}_{(0, \infty)}(x) \quad ; \forall x \in \mathbb{R}$$

وأما Y فهو متغير عشوائي متقطع بدالة احتمالية كتلية مُعطاة كما يلي:

$$P(Y = y_j) = p_j = \frac{\alpha^j}{j!} e^{-\alpha} \quad ; \forall j \in \mathbb{N}^0$$

فإذا علمنا أنَّ $0 < \lambda$ و $0 < \alpha$ قيم حقيقية ثابتة، وأنَّ دالة الكثافة الاحتمالية للمتَّجه العشوائي \mathbb{X}_2 مُعطاة من خلال العلاقة الآتية:

$$f_{\mathbb{X}_2}(x, y_j) = \lambda e^{-\lambda x} \cdot \frac{\alpha^j}{j!} e^{-\alpha} \cdot \mathbf{I}_{(0, \infty)}(x)$$

فعندئذ عيِّن دالة توزيع المتَّجه العشوائي \mathbb{X}_2 .

١٤- ليكن $X_2 = (X, Y)$ متجهاً عشوائياً مستمراً بدالة كثافة احتمالية مُعطاة بالعلاقة الآتية:

$$f_{X_2}(x, y) = \begin{cases} \alpha(x + y) & \text{for } (x, y) \in A \\ 0 & \text{otherwise} \end{cases}$$

علماً أنَّ A هي الساحة $[0, 1] \times [0, x]$ ، وأما α فهو ثابت عددي. عندئذ المطلوب ما يلي:

أ- عيّن قيمة الثابت α .

ب- عيّن دالة التوزيع لمتجه العشوائي X_2 .

ج- عيّن دوال التوزيع الهامشية لمركبات هذا المتجه العشوائي.

د- عيّن دوال التوزيع الشرطية لمركبات هذا المتجه العشوائي.

١٥- ليكن $X_2 = (X, Y)$ متجهاً عشوائياً مستمراً بدالة كثافة احتمالية مُعطاة بالعلاقة الآتية:

$$f_{X_2}(x, y) = \begin{cases} e^{\alpha(x+y)} & \text{for } (x, y) \in A \\ 0 & \text{otherwise} \end{cases}$$

علماً أنَّ المجموعة A هي المجال $(0, 1) \times (0, 1)$ ، وأما α فهو ثابت عددي، والمطلوب مايلي:

أ- عيّن قيمة الثابت α .

ب- عيّن دالة التوزيع الاحتمالية للمتجه العشوائي X_2 .

ج- عيّن دوال التوزيع الهامشية لمركبات هذا المتجه العشوائي.

د- عيّن دوال التوزيع الشرطية لمركبات هذا المتجه العشوائي.

الفصل السادس

توزيعات احتمالية شهيرة

FAMOUS PROBABILITY DISTRIBUTIONS

سنخصص هذا الفصل لتقديم بعض التوزيعات الاحتمالية الشهيرة التي لها دور مهم في الكثير من الدراسات الاحتمالية والإحصائية على حد سواء وسنبداها بالتوزيعات المتقطعة.

(٦, ١) توزيعات احتمالية متقطعة

Discrete Probability Distributions

فيما يلي نقدم بعض التوزيعات الاحتمالية المتقطعة الشهيرة التي نستعملها بأبسط نوع منها ألا وهو التوزيع الآتي:

(٦, ١, ١) التوزيع الوحيد النقطة One Point Distribution

إن سبب تسمية هذا التوزيع بهذا الاسم يعود إلى أن مجموعة قيم المتغير العشوائي X الواصف لهذا التوزيع تحتوي على قيمة وحيدة فقط (ويعرف باسم التوزيع المضمحل Degenerate Distribution أيضاً).

(٦, ١, ١, ١) تعريفه

ليكن X متغيراً عشوائياً متقطعاً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ يُقال عن X إنه خاضع للتوزيع وحيد النقطة إذا كان X ثابتاً باحتمال يساوي الواحد، أي إنه إذا وجد $c \in \mathbb{R}$ بحيث تكون العلاقة الآتية مُحَقَّقة:

$$P(X = c) = 1$$
 [6,1]


إذاً، فمن الملاحظ أن مجموعة قيم هذا المتغير العشوائي $X = \{c\}$ (قدّم كمثال في الفصل السابق) تحتوي على قيمة وحيدة c فقط، وهذه القيمة تُدعى **معلمة التوزيع** Parameter of Distribution. كذلك يُعرف هذا المتغير العشوائي باسم **المتغير العشوائي الثابت** ويقابل نموذج الدالة الثابتة في الرياضيات.

(٦, ١, ١, ٢) ملاحظات

١- يستخدم هذا النوع من المتغيرات العشوائية في المسائل التي تقتزن (أو ترتبط) فيها كل نتائج التجرب العشوائية بقيمة ثابتة واحدة فقط، وتمثيله الجدولي (أو جدول التوزيع) والبياني موضح كما يلي:

الجدول (٦, ١)

i	1	sum
x_i قيم X	c	
$p_i = P(X = x_i)$	1	1




الشكل (٦, ١). التمثيل البياني لـ X .

٢- إن دالة توزيع هذا المتغير العشوائي نجدها باستخدام تعريف دالة التوزيع لمتغير عشوائي متقطع، حيث لدينا:

$$F_X(x) = \sum_{i \in I; x_i < x} P(X = x_i) = I_{(c, +\infty)}(x) \quad ; x \in \mathbb{R}$$

كما يمكن كتابتها وفقاً للصيغ الشرطية على النحو الآتي أيضاً:

$$F_X(x) = \begin{cases} 0 & \text{for } x \leq c \\ 1 & \text{for } x > c \end{cases} \quad \text{or} \quad F_X(x) = \begin{cases} 0 & \text{if } x \leq c \\ 1 & \text{if } x > c \end{cases} \quad \text{or} \quad F_X(x) = \begin{cases} 0 & \text{for } x \leq c \\ 1 & \text{otherwise} \end{cases}$$



الشكل (٢, ٦) العرض البياني لدالة توزيع X .

فلاحظ أن دالة توزيع هذا المتغير العشوائي هي أبسط أنواع الدوال الدرجية، ولذلك يعدّ هذا المتغير العشوائي من أبسط المتغيرات العشوائية على الإطلاق.

٣- سوف نخصص رمزاً لكل متغير عشوائي شهير يتم تقديمه، فعلى سبيل المثال سنرمز للتوزيع الوحيد النقطة (التوزيع المضمحل) بالرمز $D(c)$.

٤- عندما نكتب $X \sim \Lambda(\dots)$ نقصد بذلك أن المتغير العشوائي X خاضع لتوزيع رمزه $\Lambda(\dots)$ ، فعلى سبيل المثال عندما نكتب $X \sim D(c)$ فإننا نقصد بذلك أن المتغير العشوائي X خاضع للتوزيع الوحيد النقطة في c (أو بمعلّمة c)، وهذا يعني أن العلاقة [6,1] محققة من أجل المتغير العشوائي X .

(٦, ١, ١, ٣) أمثلة

١- ليكن $[\Omega, \mathcal{A}, P]$ فضاء احتمالي، علماً أن Ω هي مجموعة كل التباديل للأعداد 1، 2 و 3، أي إن:

$$\Omega := \{\underbrace{123}_{\omega_1}, \underbrace{132}_{\omega_2}, \underbrace{213}_{\omega_3}, \underbrace{231}_{\omega_4}, \underbrace{312}_{\omega_5}, \underbrace{321}_{\omega_6}\}$$

وأما \mathcal{A} سنأخذه موافقاً للجبر القوي فوق Ω ، أي إن $\mathcal{A} = 2^\Omega$ ، وأخيراً سنأخذ الدالة الاحتمالية P كما يلي:

$$P(A) = \sum_{i=1}^6 Q(\{\omega_i\}) \quad A \in \mathcal{A} \quad \text{with} \quad \sum_{i=1}^6 Q(\{\omega_i\}) = 1$$

ولنأخذ X تطبيقاً حقيقياً معرفاً فوق Ω بحيث يُقرن كل حادث ابتدائي ω_i بعدد يساوي مجموع الأعداد المكوّنة لهذا الحادث الابتدائي، أي إن:

$$X : \Omega \longrightarrow \mathbb{R} \quad ; \omega_i \mapsto X(\omega_i) = 6 \quad ; \forall i \in \mathbb{N}_6$$

ف نجد أن هذا التطبيق هو متغير عشوائي (تحقق من صحة ذلك) ويأخذ قيمة وحيدة هي 6، ومن ثم يكون $X \sim D(6)$ (أي إن هذا المتغير العشوائي خاضع للتوزيع الوحيد النقطة في $c=6$).

٢- ليكن $[\Omega, \mathcal{A}, P]$ فضاءً احتمالياً، علماً أن:

$$\Omega := \left\{ \omega_n := \frac{1}{n} ; n \in \mathbb{N} \right\}$$

وأما \mathcal{A} سنأخذه موافقاً للجبر القوي فوق Ω ، أي إن $\mathcal{A} = 2^\Omega$ ، وأخيراً سنأخذ الدالة الاحتمالية P المعطاة كما يلي:

$$P(A) = \sum_{n=1; \omega_n \in A}^{\infty} Q(\{\omega_n\}) ; \forall A \in \mathcal{A} \quad \text{with } Q(\{\omega_n\}) = Q(\{1/n\}) = \frac{6}{\pi^2 n^2}$$

ولنأخذ X تطبيقاً حقيقياً معرفاً فوق Ω بحيث يقرن كل حادث ابتدائي ω_n بالعدد π ، أي إن:

$$X : \Omega \longrightarrow \mathbb{R} ; \omega_n \mapsto X(\omega_n) = \pi ; \forall n \in \mathbb{N}$$

ف نجد أن هذا التطبيق هو متغير عشوائي (تحقق من صحة ذلك) ويأخذ قيمة وحيدة هي π ، ومن ثم نجد أن $X \sim \mathbf{D}(\pi)$.

٣- ليكن لدينا فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، علماً أن:

$$\Omega = [a, b] \quad \& \quad \mathcal{A} = \mathcal{R} \cap [a, b] \quad \& \quad P(A) = \frac{1}{b-a} \int_A dx ; \forall A \in \mathcal{A}$$

ولنأخذ X تطبيقاً حقيقياً معرفاً فوق Ω بحيث يقرن كل حادث ابتدائي ω من Ω بالحد الأعلى للفترة $[a, b]$ ، أي إن:

$$X : \Omega \longrightarrow \mathbb{R} ; \omega \mapsto X(\omega) = b$$

ف نجد أن هذا التطبيق هو متغير عشوائي (تحقق من صحة ذلك) ويأخذ قيمة وحيدة هي b ، ومن ثم يكون $X \sim \mathbf{D}(b)$.

(٤، ١، ٦) ملاحظة

من الأمثلة السابقة نلاحظ أن طبيعة مجموعة نتائج التجربة العشوائية Ω لا تهمنا بشيء منتهية كانت أم غير منتهية، قابلة للعد أو غير قابلة للعد، وكذلك بالنسبة إلى احتمالات الحوادث الابتدائية، فمن غير المهم إن كانت متساوية الاحتمال أو غير متساوية الاحتمال. إنما المهم في المتغيرات العشوائية المتقطعة هو عدد القيم التي يأخذها المتغير العشوائي X فقط، وأما احتمالات أخذ المتغير العشوائي X لتلك القيم فإنه يتعلق بشكل مباشر بطبيعة مجموعة نتائج التجربة العشوائية Ω وباحتمالات حوادثها الابتدائية.

(٢، ١، ٦) التوزيع ثنائي النقطة (أو توزيع برنولي) **Tow Point Distribution (or Bernoulli Distribution)**

إن هذا النوع من المتغيرات العشوائية المتقطعة (قدم أحد نماذجها كمثال في الفصل السابق) يأتي كثاني أبسط متغير عشوائي متقطع لأنه يأخذ قيمتين فقط، والتعريف الآتي يوضح لنا ذلك.

(١، ٢، ٦) تعريفه

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ يُقال عن X إنه خاضع للتوزيع ثنائي النقطة في x_1 و x_2 من \mathbb{R} مع $x_1 \neq x_2$ ، إذا كان قانون توزيعه محققاً للعلاقتين الآتيتين:

$$\left. \begin{aligned} P(X = x_1) &= p \\ P(X = x_2) &= 1 - p \end{aligned} \right\}$$

[6,2]

علماً أن $0 < p < 1$ يدعى معلمة التوزيع.

(٢، ٢، ٦) ملاحظات

١- سنستخدم الرمز $\mathbf{B}(p)$ للدلالة على هذا التوزيع، وكذلك سنرمز بـ $\mathbf{b}(x_i; p)$ للدلالة على قيمة الكتلة الاحتمالية $P(X = x_i)$ لهذا المتغير العشوائي X عند القيمة x_i ، أي إنه من أجل $i \in \{1, 2\}$ لدينا $\mathbf{b}(x_i; p) \triangleq P(X = x_i)$.

٢- في الحالة الخاصة عندما تكون $x_1 = 1$ و $x_2 = 0$ فعندئذ يُقال عن القيمة p إنها **احتمال النجاح** Success Probability، وأما القيمة $q := 1 - p$ فتدعى **احتمال الفشل** Failure Probability، والسبب في ذلك أنه تُعطى (عادة) القيمة $x_1 = 1$ عندما نحصل على النتيجة التي نصبو إليها أو نبتغيها، ولذلك يُقال إننا قد حصلنا على نجاح، في حين أن القيمة $x_2 = 0$ تُعطى (عادة) عندما نفشل في الحصول على النتيجة التي نصبو إليها أو نبتغيها، ولذلك يُقال إننا قد فشلنا في الحصول على النتيجة المرجوة. من أجل هذه الحالة الأخيرة يصبح للمتغير العشوائي X تسمية أخرى حيث يُقال عنه **متغير عشوائي برنولي** Bernoulli Random Variable نسبة إلى الرياضي السويسري **برنولي** (1655-1705) Jacob Bernoulli، وهنا تجدر الإشارة إلى أن الرياضي **يعقوب برنولي** هو أول من قام بتقديم دراسة علمية متقنة للتجارب التي تتمخض عنها إحدى نتيجتين، وسميت فيما بعد بـ **التجارب البرنولية** Bernoulli Experiments تخليداً لذكراه، وأما المتغيرات العشوائية المرافقة لهذه التجارب فتدعى **متغيرات عشوائية برنولية** كما ذكر آنفاً. لاحظ أنه من أجل هذا النوع من المتغيرات العشوائية يُنظر إلى كل نتيجة محتملة على أنها إما نجاح أو فشل.

٣- يستخدم هذا النوع من المتغيرات العشوائية في المسائل التي تترن فيها أية نتيجة من نتائج التجرب العشوائية بإحدى نتيجتين فقط، ومنها على سبيل المثال: رمي قطعة نقود لمرة واحدة، فاعلية عقار دوائي ضد مرض معين، أو...

٤- التمثيل الجدولي (جدول التوزيع) والبياني لهذا المتغير العشوائي من أجل الحالتين المذكورتين أعلاه موضح كما يلي:


الجدول (٢، ٦. أ)

i	1	2	sum
x_i قيم X	x_1	x_2	
$p_i = P(X = x_i)$	p	$q := 1 - p$	1

الجدول (٢، ٦. ب)


i	1	2	sum
x_i قيم X	0	1	
$p_i = P(X = x_i)$	$q := 1 - p$	p	1

٥- التمثيل البياني لهذا المتغير العشوائي يقدمه لنا الشكلان الآتيان:



٦- إذا كان $x_2 > x_1$ فإنه سيكون لدالة توزيع هذا المتغير العشوائي العرض والشكل الآتيين:


$$F_X(x) = \begin{cases} 0 & \text{for } x \leq x_1 \\ p & \text{for } x_1 < x \leq x_2 \\ p + (1-p) = 1 & \text{for } x > x_2 \end{cases}$$



الشكل (٤، ٦. أ) دالة التوزيع الاحتمالية من أجل $x_2 > x_1$.

وأما إذا كان $x_1 > x_2$ فإنه سيصبح لدالة توزيع هذا المتغير العشوائي العرض والشكل الآتيين:


$$F_X(x) = \begin{cases} 0 & \text{for } x \leq x_2 \\ 1-p & \text{for } x_2 < x \leq x_1 \\ 1 & \text{for } x > x_1 \end{cases}$$



الشكل (٤، ٦. ب) دالة التوزيع الاحتمالية من أجل $x_1 > x_2$.

ومن أجل الحالة البرنولية سيتج لدينا أن لدالة توزيع هذا المتغير العشوائي العرض والشكل الآتيين:

$$F_X(x) = \begin{cases} 0 & \text{for } x \leq 0 \\ 1-p & \text{for } 0 < x \leq 1 \\ 1 & \text{for } x > 1 \end{cases}$$



الشكل (٤، ٦. ج) دالة التوزيع الاحتمالية من أجل الحالة البرنولية.

(٦، ١، ٢، ٣) أمثلة

١- بالعودة إلى المثال / ١ / من (٦، ١، ٢، ٣) حيث لدينا:

$$\Omega := \{\underbrace{123}_{\omega_1}, \underbrace{132}_{\omega_2}, \underbrace{213}_{\omega_3}, \underbrace{231}_{\omega_4}, \underbrace{312}_{\omega_5}, \underbrace{321}_{\omega_6}\}$$

ولنأخذ X تطبيقاً حقيقياً معرفاً فوق Ω على النحو الآتي:

$$X : \Omega \longrightarrow \mathbb{R} ; \omega \mapsto X(\omega) = \begin{cases} 0 & \text{for } \omega = 213, 312, 231 \\ 1 & \text{for } \omega = 123, 321, 132 \end{cases}$$

ف نجد أن هذا التطبيق هو متغير عشوائي (تحقق من صحة ذلك) ويأخذ قيمتين فقط هما 0 و 1 بالاحتمال نفسه، ومن ثم يكون لهذا المتغير العشوائي توزيع ثنائي النقطة في $x_1 = 1$ و $x_2 = 0$ ، وكما هو ملاحظ فإن لهذا المتغير العشوائي عرضاً برنولياً واحتمال النجاح له يساوي 0.5، أي إن $X \sim B(0.5)$.

٢- بالعودة إلى المثال /٢/ من (١, ١, ١, ٣) حيث لدينا $\Omega = \left\{ \omega_n = \frac{1}{n} ; n \in \mathbb{N} \right\}$ ، فلو أخذنا X تطبيقاً حقيقياً فوق Ω معرفاً من خلال العلاقة الآتية:

$$X : \Omega \longrightarrow \mathbb{R} ; \omega_n \mapsto X(\omega_n) = \begin{cases} 0 & \text{for } n \text{ even} \\ 1 & \text{for } n \text{ odd} \end{cases}$$

لوجدنا أن هذا التطبيق هو متغير عشوائي (تحقق من صحة ذلك) ويأخذ قيمتين فقط، ومن ثم يكون هذا المتغير العشوائي خاضعاً للتوزيع ثنائي النقطة في $x_1 = 1$ و $x_2 = 0$ ، وبما أن $P(\Omega) = 1$ فإنه سيكون لدينا:

$$\begin{aligned} 1 = P(\Omega) &= P\left(\left\{\frac{1}{n} ; n \in \mathbb{N}, n \text{ odd}\right\} + \left\{\frac{1}{n} ; n \in \mathbb{N}, n \text{ even}\right\}\right) \\ &= P\left(\left\{\frac{1}{n} ; n \in \mathbb{N}, n \text{ odd}\right\}\right) + P\left(\left\{\frac{1}{n} ; n \in \mathbb{N}, n \text{ even}\right\}\right) \end{aligned}$$

لأن الحادتين $\left\{\frac{1}{n} ; n \in \mathbb{N}, n \text{ odd}\right\}$ و $\left\{\frac{1}{n} ; n \in \mathbb{N}, n \text{ even}\right\}$ متنافيان، وبما أن $\sum_{n=1}^{\infty} \frac{1}{n^2} = \frac{\pi^2}{6}$ ، فإنه سيكون لدينا:

$$\begin{aligned} P\left(\left\{\frac{1}{n} ; n \in \mathbb{N}, n \text{ even}\right\}\right) &= \sum_{n=1; n \text{ even}}^{\infty} Q(\{\omega_n\}) = \sum_{n=1; n \text{ even}}^{\infty} \frac{\pi^2}{6} \frac{1}{n^2} \\ &= \frac{6}{\pi^2} \sum_{n=1}^{\infty} \frac{1}{(2n)^2} = \frac{6}{4\pi^2} \sum_{n=1}^{\infty} \frac{1}{n^2} = \frac{1}{4} = q \end{aligned}$$

أي إن قيمة معلمة هذا التوزيع $p = 0.75$ ، ومن ثم $X \sim \mathbf{B}(0.75)$.

لاحظ هنا أنه لا يمكننا استنتاج قيم مثل هذه الاحتمالات باستخدام مبدأ لابلاس في الاحتمالات لأن عدد الحوادث الابتدائية في أي من الحادتين غير منته، فعلى سبيل المثال استخدام فكرة أن الأعداد الفردية والزوجية في \mathbb{N} تتناوب على التوالي فإنه سيكون (عددين موجبين متساويين مجموعهما الواحد) $P(X=0)=0.5$ و $P(X=1)=0.5$ ، ولكن الدراسة السابقة أظهرت أن هذا الاستنتاج الأخير ليس صحيحاً، بمعنى أن النتائج الاحتمالية التي نحصل عليها عندما تكون Ω منتهية قد تختلف كلياً في حال أصبحت Ω غير منتهية.

٣- ليكن لدينا $[\Omega, \mathcal{A}, P]$ فضاء احتمالياً، علماً أن:

$$\Omega = [0, 1] \quad \& \quad \mathcal{A} = \mathcal{R} \cap [0, 1] \quad \& \quad P(A) = \int_A dx ; \forall A \in \mathcal{A}$$

ولنأخذ X تطبيقاً حقيقياً معرفاً فوق Ω كما في العلاقة الآتية:

$$X : \Omega \longrightarrow \mathbb{R} ; \omega \mapsto X(\omega) = \begin{cases} 0 & \text{for } \omega \in \left[0, \frac{1}{4}\right) \\ 1 & \text{for } \omega \in \left[\frac{1}{4}, 1\right] \end{cases}$$

عندئذ نجد أن:

$$\{\omega \in \Omega ; X(\omega) < x\} = \begin{cases} \emptyset & \text{for } x \leq 0 \\ \left[0, \frac{1}{4}\right) & \text{for } 0 < x \leq 1 \\ [0, 1] & \text{for } x > 1 \end{cases}$$

وبما أن \emptyset و $\Omega = [0, 1]$ هي عناصر من \mathcal{A} دوماً، وكذلك لدينا $\left[0, \frac{1}{4}\right)$ هو عنصر من \mathcal{A} أيضاً لأنها مجموعة بوريلية في الفترة

$[0,1]$ ، فإن ذلك يعني إن التطبيق X هو متغير عشوائي فوق $[\Omega, \mathcal{A}, P]$ ، وبملاحظة أن X يأخذ قيمتين فقط، فهذا يعني أن هذا المتغير العشوائي خاضع للتوزيع الثنائي النقطة في $x_1 = 1$ و $x_2 = 0$ ، وقيمة معلّمة نجدها كما يلي:

$$p = P(X = 1) = P\left(\left[\frac{1}{4}, 1\right]\right) = \int_{\frac{1}{4}}^1 dx = x \Big|_{\frac{1}{4}}^1 = 1 - \frac{1}{4} = \frac{3}{4} = 0.75$$

ومن ثم يكون $X \sim \mathbf{B}(0.75)$.

(٦, ١, ٣) التوزيع المنتظم المتقطع Discrete Uniform Distribution

إن سبب تسمية هذا التوزيع بهذا الاسم تعود إلى قيم الكتل الاحتمالية $P(X = x_i)$ لهذا المتغير العشوائي حيث سنلاحظ أن X يأخذ جميع قيمه بالاحتمال نفسه (قدّم أحد نماذجه كمثال في الفصل السابق)، أي إن قيم احتمالاته منتظمة على كل القيم التي يأخذها (انظر التمثيل البياني الآتي لهذا المتغير العشوائي الذي يوضح معنى ذلك).

(٦, ١, ٣, ١) تعريفه

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ يُقال عن X إنه خاضع للتوزيع المنتظم المتقطع إذا كان يأخذ عدداً منتهياً من القيم الحقيقية x_1, x_2, \dots, x_n ، وقانون توزيعه P_X يُحقّق العلاقة الآتية:

$$P(X = x_i) = \frac{1}{n} ; \forall i \in \mathbb{N}_n \quad [6,3]$$

علماً أن n هو عدد صحيح موجب تماماً ويدعى **معلّمة التوزيع**.

(٦, ١, ٣, ٢) ملاحظة

١- سنستخدم الرمز $U(n)$ للدلالة على هذا التوزيع، وسنرمز بـ $u(x_i; n)$ للدلالة على قيمة الكتلة الاحتمالية لهذا المتغير العشوائي X عند القيمة x_i ، أي إن $u(x_i; n) \triangleq P(X = x_i)$.


٢- لاحظ هنا أنه عندما يكون للمتغير العشوائي X قيمة وحيدة x_1 فإن هذا التوزيع يوافق توزيع وحيد النقطة بمعلّمة $c = x_1$ كحالة خاصة، وكذلك عندما يكون لـ X قيمتين x_1 و x_2 فإن هذا التوزيع سيوافق التوزيع الثنائي النقطة بمعلّمة $p = \frac{1}{2}$ كحالة خاصة.

٣- يستخدم هذا النوع من المتغيرات العشوائية في المسائل التي تقترن فيها أية نتيجة من نتائج التجربة العشوائية بإحدى n قيمة حقيقية لها النصيب نفسه في الاختيار.

٤- التمثيل الجدولي لوالبياني لهذا المتغير العشوائي موضح كما يلي:

الجدول (٦, ٣)

i	1	2	n	sum
X قيم x_i	x_1	x_2	x_n	
$p_i = P(X = x_i)$	$\frac{1}{n}$	$\frac{1}{n}$	$\frac{1}{n}$	1



الشكل (٦, ٥)


٦- لدى استخدام تعريف دالة توزيع متغير عشوائي متقطع نجد إن لدالة توزيع هذا المتغير العشوائي العرض الآتي:

$$F_X(x) = \frac{i}{n} \mathbf{I}_{(x_i, x_{i+1}]}(x) + \mathbf{I}_{(x_n, +\infty)}(x) ; \forall x \in \mathbb{R}$$

والتي يمكن كتابتها وفقاً للصيغة الشرطية بالشكل الآتي أيضاً:

$$F_X(x) = \begin{cases} 0 & \text{if } x \leq x_1 \\ \frac{i}{n} & \text{if } x_i < x \leq x_{i+1} \text{ for } i \in \mathbb{N}_{n-1} \\ 1 & \text{if } x > x_n \end{cases}$$

وأما العرض البياني لدالة توزيع هذا المتغير العشوائي فهي على النحو الآتي:



الشكل (٦, ٦)

أمثلة (٦, ١, ٣, ٣)

١- لنأخذ تجربة إلقاء حجر نرد متوازن مرة واحدة فقط، وليكن X متغيراً عشوائياً فوق الفضاء الاحتمالي لهذه التجربة، ومعرفة من خلال العلاقة الآتية:

$$X(\omega) := \frac{1}{\omega} \quad ; \quad \forall \omega \in \Omega$$

ف نجد أن هذا المتغير العشوائي خاضع للتوزيع المنتظم المتقطع بمعلمة $n = 6$ ، وأما مجموعة قيمه فهي:

$$X = \left\{ \frac{1}{6}, \frac{1}{5}, \frac{1}{4}, \frac{1}{3}, \frac{1}{2}, 1 \right\}$$

واحتمال أن يأخذ هذا المتغير العشوائي أية قيمة من قيمه تساوي $\frac{1}{6}$ ، وذلك لأنه بسبب توازن حجر النرد لدينا:


$$P\left(\left\{\omega \in \Omega ; X(\omega) = \frac{1}{\omega}\right\}\right) = P(\{\omega\}) = \frac{1}{6} \quad ; \quad \forall \omega \in \Omega$$

أي إنه من أجل كل $i \in \mathbb{N}_6$ لدينا $P(X = x_i) = \frac{1}{6}$.

٢- لنأخذ تجربة إلقاء قطعة نقود متوازنة لثلاث مرات متتالية، وليكن X متغيراً عشوائياً فوق الفضاء الاحتمالي لهذه التجربة راصداً لعدد الصور التي ستظهر للأعلى، فعندئذ نجد أن مجموعة قيمه هي $X = \{0, 1, 2, 3\}$ ، وسنفترض أن الاحتمالات الكتلية لهذا المتغير العشوائي هي:

$$P(X = 0) = \frac{1}{8} \quad \& \quad P(X = 1) = \frac{3}{8}$$

$$P(X = 2) = \frac{3}{8} \quad \& \quad P(X = 3) = \frac{1}{8}$$



الشكل (٦, ٦) والتمثيل البياني للمتغير العشوائي X

فلاحظ أن هذا المتغير العشوائي لا يخضع للتوزيع المنتظم المتقطع، والتمثيل البياني أعلاه لهذا المتغير العشوائي يوضح لنا ذلك أيضاً.

(٤, ١, ٦) التوزيع الحداني Binomial Distribution

إنَّ هذا المتغير العشوائي (قدَّم أحد نماذجه كمثال في الفصل السابق) يُعدُّ من المتغيرات العشوائية المهمة في الكثير من الدراسات التطبيقية.

(١, ٤, ١, ٦) تعريفه

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ يُقال عن X إنه خاضع للتوزيع الحداني بمعلمتين $n \in \mathbb{N}$ و $0 < p < 1$ إذا كان يأخذ قيماً صحيحة غير سالبة، وكان قانون توزيعه مُعطى من خلال العلاقة الآتية:

$$P(X = k) = \binom{n}{k} \cdot p^k \cdot (1-p)^{n-k} ; k \in \mathbb{N}_n^0 \quad [6,4]$$

نشير هنا إلى أنَّ سبب تسمية هذا التوزيع بهذا الاسم يعود إلى الصيغة التي تُعطي مجموع الكتل الاحتمالية $P(X = k)$ والتي لها صيغة مطابقة للحد العام في منشور ثنائي الحد الشهير $(x + y)^n$ والمعروف باسم **نشر الكرخي - نيوتن** Karkhi - Newton expression (نسبة إلى الفيلسوف والرياضياتي أبو بكر بن محمد بن حسين الكرخي **Abū Bakr ibn Muḥammad ibn al Ḥusayn Al-Karajī** (953-1029)، وكذلك الرياضياتي والفيزيائي الإنكليزي نيوتن (Sir Isaac Newton (1642-1726)، ولصيغته هذا النشر العرض الآتي:

$$(x + y)^n = \sum_{k=0}^n \binom{n}{k} \cdot x^k \cdot y^{n-k}$$

حيث لدينا:

$$1 = (p + (1-p))^n = \sum_{k=0}^n \binom{n}{k} \cdot p^k \cdot (1-p)^{n-k}$$

(٢, ٤, ١, ٦) ملاحظات

١- سوف نستخدم الرمز $B(n, p)$ للدلالة على هذا التوزيع، وكذلك سنرمز بـ $b(k; n, p)$ للدلالة على قيمة الكتلة الاحتمالية لهذا المتغير العشوائي X عند القيمة k ، أي إنَّ:

$$b(k; n, p) \triangleq P(X = k)$$

٢- إنَّ هذا النوع من المتغيرات العشوائية يستخدم في التجارب العشوائية التي هي حصيلة n تكرار مستقل لتجارب برنولية باحتمال نجاح p ، ويكون في هذه الحالة المتغير العشوائي X راصداً لعدد النجاحات التي نحصل عليها خلال الـ n تجربة. هنا يجب التأكيد على استقلالية التكرارات للتجارب البرنولية، فلو افترضنا على سبيل المثال أنَّ شخصاً ما يقوم بتوزيع بطاقات لعب، فعندئذ نلاحظ أنَّ الاحتمالات للمحاولات المتكررة يتغير إذا لم يتم استبدال البطاقات. فاحتمال سحب بطاقة من نوع القلب في السحب الأول هو $1/4$ ، ولكن في السحب الثاني هو $12/51$ أو $13/51$ ، وهذا يتوقف على بطاقة القلب إن كانت قد ظهرت في السحب الأول أم لا، وهنا نكون أمام احتمال شرطي، ومن ثمَّ فلا يمكننا النظر إلى هذه المحاولات المتكررة على أنَّها تكرارات برنولية مستقلة.



٣- التمثيل الجدولي لهذا المتغير العشوائي (من أجل $n = 5$ و $p = 0.5$) يقدمه لنا الجدول الآتي:

الجدول (٤, ٦)



i	1	2	3	4	5	6	sum
x_i قيم X	0	1	2	3	4	5	
$p_i = P(X = x_i)$	0.031	0.156	0.313	0.313	0.156	0.031	1

وأما التمثيل البياني لهذا المتغير العشوائي فسوف نقدِّمه من خلال عروض عديدة موافقة لقيم مختلفة للمعلمتين n و p ، حيث نحصل

على العروض الآتية:

الشكل (٦,٧.ب) من أجل $n = 5$ و $p = 0.5$ الشكل (٦,٧.أ) من أجل $n = 100$ و $p = 0.5$

فلاحظ أنه من أجل القيم المعطاة آنفاً سيكون توزيع هذا المتغير العشوائي متناظر، وأنه في الشكل (٦,٧.أ) لدينا قيم الاحتمالات الموافقة لـ $k > 32$ و $k < 68$ صغيرة لدرجة يصعب إيضاحها بالرسم.

الشكل (٦,٧.د) من أجل $n = 25$ و $p = 0.8$ الشكل (٦,٧.ج) من أجل $n = 25$ و $p = 0.2$


وأما هنا، فنلاحظ أنه من أجل القيم المعطاة آنفاً قد أصبح التوزيع ملتوياً، وفي الشكل (٦,٧.ج) الالتواء نحو اليمين وقيم الاحتمالات الموافقة لـ $k < 12$ صغيرة بحيث يصعب إيضاحها بالرسم، وأما في الشكل (٦,٧.د) فإننا نجد أن الالتواء نحو اليسار وقيم الاحتمالات الموافقة لـ $k > 12$ صغيرة بحيث يصعب إيضاحها بالرسم.

٥- إن دالة توزيع هذا المتغير العشوائي نجدها باستخدام تعريف دالة توزيع متغير عشوائي متقطع، حيث لدينا:

$$F_X(x) = \sum_{\substack{k=0 \\ k \leq x}}^n \binom{n}{k} p^k (1-p)^{n-k} \quad ; \forall x \in \mathbb{R}$$

ومن أجل $n = 5$ و $p = 0.5$ يصبح لها العرض الآتي:

$$F_X(x) = \begin{cases} 0 & \text{for } x \leq 0 \\ 0.0313 & \text{for } 0 < x \leq 1 \\ 0.1875 & \text{for } 1 < x \leq 2 \\ 0.5000 & \text{for } 2 < x \leq 3 \\ 0.8125 & \text{for } 3 < x \leq 4 \\ 0.9688 & \text{for } 4 < x \leq 5 \\ 1 & \text{for } x > 5 \end{cases}$$

الشكل (٦,٨) دالة التوزيع الاحتمالية من أجل $n = 5$ و $p = 0.5$.

في الحقيقة عندما تكون قيمة المعلمة n كبيرة جداً و p صغيرة جداً فإن حساب قيمة الدالة F_X يصبح شاقاً، لا بل قد يكون من غير الممكن حسابها بالوسائط البسيطة، ولذلك يلجأ المرء في مثل هذه الحالات إلى استخدام الجداول (كالجدول الخاص بهذا التوزيع الموجود في نهاية هذا الكتاب)، أو استخدام آلات حاسبة متطورة، أو اللجوء إلى استخدام توزيع آخر كتقريب لهذا التوزيع، وسنعالج هذه الفقرة في نهاية هذا الفصل. كما يمكن استخدام صيغ تكاملية مناسبة مثل صيغة تكامل بيتا المنقوص من أجل إعطاء قيم تقريبية مقبولة لقيم هذه الدالة، علماً أن الصيغة التكاملية لتكامل بيتا المنقوص تعطى من خلال العلاقة الآتية:

$$\beta_{n,x} = (n-x) \binom{n}{x} \int_0^1 t^{n-x-1} (1-t)^x dt \quad ; x \in \mathbb{R}, n \in \mathbb{N}$$

حيث يبرهن أنه من أجل كل $x \in \mathbb{R}$ يكون لدينا:

$$F_X(x) = (n - \lfloor x \rfloor) \binom{n}{\lfloor x \rfloor} \int_0^{1-p} t^{n-\lfloor x \rfloor-1} (1-t)^x dt$$

مع العلم أن $\lfloor x \rfloor$ هو أكبر عدد صحيح أصغر أو يساوي x .

(٦, ١, ٤, ٣) أمثلة

١- لنقم بإلقاء قطعة نقود سبع مرات متتالية، فإذا كان احتمال ظهور الشعار في الرمية الواحدة يساوي 0.3، فما هو احتمال الحصول على شعارين على الأقل خلال الرميات السبع؟

الحل: للإجابة على هذا السؤال سنفترض أن X متغير عشوائي راصد لعدد الشعارات التي نحصل عليها خلال الرميات السبع لقطعة النقود، فعندئذ يكون X خاضعاً للتوزيع الحداني بمعلمتين $n=7$ و $p=0.3$ وذلك لأن التكرارات لعملية إلقاء قطعة النقود هي تكرارات لتجارب برنولية مستقلة بعضها عن البعض الآخر، واحتمال النجاح في كل منها يساوي $p=0.3$ ، وأما المطلوب فهو $P(X \geq 2)$ حيث لدينا:

$$\begin{aligned} P(X \geq 2) &= 1 - P(X < 2) = 1 - [P(X=0) + P(X=1)] \\ &= 1 - [b(0; 7, 0.3) + b(1; 7, 0.3)] = 1 - [0.0824 + 0.2471] = 0.6705 \end{aligned}$$

٢- يقوم رجل بالرمي على هدف معين وبحيث لا يعلم شيئاً عن إصابته للهدف، فإذا كان احتمال إصابة الرجل للهدف في كل رمية تساوي 0.8، وقام بإطلاق 10 رميات على الهدف، فما هو احتمال أن يصيب الهدف بتسع رميات تماماً؟

الحل: ليكن X متغيراً عشوائياً راصداً لعدد الرميات التي تصيب الهدف، فعندئذ يكون هذا المتغير العشوائي خاضعاً للتوزيع الحداني بمعلمتين $n=10$ و $p=0.8$ ؛ وذلك لأن كل عملية رمي من قبل الرجل هي تجربة برنولية بمعلمة $p=0.8$ وتكرارات هذه التجارب مستقل بعضها عن البعض الآخر (لأن الرامي لا يعلم شيئاً عن إصابته للهدف)، ومن ثم يكون الاحتمال المطلوب هو:

$$P(X=9) = \binom{10}{9} (0.8)^9 (0.2) = 0.2684$$

(٦, ١, ٥) التوزيع الحداني السالب Negative Binomial Distribution

إن آلية عمل هذا المتغير العشوائي تشابه آلية عمل المتغير العشوائي السابق، وهو من المتغيرات العشوائية المهمة أيضاً.

(٦, ١, ٥, ١) تعريفه

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ يقال عن X إنه خاضع للتوزيع الحداني السالب (أو توزيع باسكال Pascal Distribution نسبة إلى الرياضي والفيزيائي الفرنسي باسكال (Blaise Pascal (1623-1662) بمعلمتين $n \in \mathbb{N}$ و $0 < p < 1$ إذا كان يأخذ قيماً صحيحة غير سالبة، وكان قانون توزيعه معطى من خلال العلاقة الآتية:

$$P(X = k) = \binom{k+n-1}{k} \cdot (1-p)^k \cdot p^n \quad ; k \in \mathbb{N}^o \quad [6,5-a]$$

أو وفقاً للصيغة الآتية:

$$P(X = k) = \binom{k+n-1}{n-1} \cdot (1-p)^k \cdot p^n \quad ; k \in \mathbb{N}^o \quad [6,5-b]$$

ونشير هنا إلى أن سبب تسمية هذا التوزيع بهذا الاسم يعود إلى صيغة التوافيق الآتية التي تظهر لنا توافق لقيم سالبة لـ n :

$$\binom{k+n-1}{k} = (-1)^r \binom{-n}{k} = (-1)^r \frac{(-n) \cdot (-n-1) \cdot \dots \cdot (-n-k+1)}{(k) \cdot (k-1) \cdot \dots \cdot (2) \cdot (1)}$$

(٢, ١, ٥, ٦) ملاحظات

١- سوف نستخدم الرمز $\tilde{B}(n, p)$ للدلالة على هذا التوزيع، وكذلك سنرمز بـ $\tilde{b}(k; n, p)$ للدلالة على قيمة الكتلة الاحتمالية لهذا المتغير العشوائي X عند القيمة k ، أي إن:

$$\tilde{b}(k; n, p) \triangleq P(X = k)$$

٢- يستخدم هذا النوع من المتغيرات العشوائية في التجارب العشوائية التي هي حصىلة تكرارات مستقلة لتجارب برنولية باحتمال نجاح p ، وهنا يرصد المتغير العشوائي X عدد التجارب التي نحصل فيها على فشل حتى يتم الحصول على n نجاحاً تماماً.

٣- إذا كان اهتمامنا منصباً على عدد التجارب k التي يجب أن تنفذ حتى الحصول على n نجاحاً (ومن ثم يكون لدينا $k - n$ فشلاً)، فعندئذ سيصبح لقانون توزيع X العرض الآتي:

$$P(X = k) = \binom{k-1}{n-1} p^n (1-p)^{k-n} \quad [6,5-c]$$


علماً أن قيم k في هذه العلاقة الأخيرة تبدأ من $n+1$ ، ثم $n+2$ ، ثم $n+3$...

٤- لتوضيح العرض الجدولي لهذا المتغير العشوائي سنأخذ قيمياً محددة للمعلمتين، فمن أجل $n = 2$ و $p = 0.5$ يكون لدينا التمثيل الجدولي الآتي لهذا المتغير العشوائي.


الجدول (٥, ٦)

i	1	2	3	4	5	6	sum
x_i قيم X	0	1	2	3	4	5	
$p_i = P(X = x_i)$	0.250	0.250	0.187	0.125	0.078	0.046	≈ 1

٥- التمثيل البياني لهذا المتغير العشوائي من أجل قيم مختلفة لـ n و p يقدمها الشكلين الآتين.



شكل (٩, ٦). ب. من أجل $n = 2$ و $p = 0.5$




الشكل (٩, ٦). أ. من أجل $n = 10$ و $p = 0.5$

٦- باستخدام تعريف متغير عشوائي متقطع نجد لدالة توزيع هذا المتغير العشوائي العرض الآتي:

$$F_X(x) = p^n \cdot \sum_{\substack{k=0 \\ k < x}} \binom{k+n-1}{k} \cdot (1-p)^k \quad ; x \in \mathbb{R}$$

والتي يمكن عرضها من أجل $n=2$ و $p=0.5$ على النحو الآتي:

$$F_X(x) = \begin{cases} 0 & \text{for } x \leq 0 \\ 0.25 & \text{for } 0 < x \leq 1 \\ 0.50 & \text{for } 1 < x \leq 2 \\ 0.6875 & \text{for } 2 < x \leq 3 \\ 0.8125 & \text{for } 3 < x \leq 4 \\ \vdots & \vdots \quad \vdots \quad \vdots \\ 1 & \text{for } x \rightarrow \infty \end{cases}$$



الشكل (١٠، ٦). دالة التوزيع الاحتمالية من أجل $n=2$ و $p=0.5$.

(٣، ٥، ١، ٦) أمثلة

١- لنفترض أن باحثاً يقوم بتنفيذ تجربة للتحقق من نتيجة معينة، ويكرر تنفيذ هذه التجربة تحت الشروط نفسها وبشكل مستقل كل منها عن الأخرى، فإذا افترضنا أن احتمال تحقق النتيجة المرجوة يساوي 0.05، وأنه سيتوقف عن تنفيذ التجربة عندما تتحقق النتائج المرجوة في ثلاث منها، فما هو احتمال أن يقوم الباحث بتنفيذ خمس تجارب تماماً؟

الحل: في هذا المثال نلاحظ أن التجارب الخمس هي تجارب برنولية مستقلة بعضها عن بعض، واحتمال النجاح لكل تجربة هو $p=0.05$ ، فلو كان X متغير عشوائي راصد لعدد التجارب التي سيفشل الباحث في تنفيذها حتى يتم الحصول على ثلاث نتائج إيجابية بخصوص المسألة التي هي قيد الدرس، لو وجدنا أن هذا المتغير العشوائي خاضع للتوزيع الحداني السالب بمعلمتين $n=3$ و $p=0.05$ ، ومن ثم احتمال الحصول على فشليين فقط قبل حصولنا على النجاح الثالث يساوي:

$$P(X=2) = \tilde{b}(2; 3, 0.05) = \binom{2+3-1}{2} (0.05)^3 (0.95)^2 = 0.0007$$

٢- تقوم آلة بانتاج نوع من السجاد، فإذا افترضنا أن احتمال إنتاج سجادة خالية من العيوب في كل مرة يساوي 0.85 وأن الآلة ستتوقف عن الإنتاج إذا صار عدد السجاد المعيب في إنتاجها يساوي ثلاث سجادات، فما هو احتمال توقف الآلة عن الإنتاج بعد تصنيع السجادة التاسعة؟

الحل: في هذا المثال نلاحظ أن عملية إنتاج السجاد هي تجارب برنولية مستقلة بعضها عن البعض الآخر باحتمال نجاح $p=0.15$ (لأن النجاح هنا هو الحصول على سجادة معيبة)، فلو كان X متغير عشوائي راصد لعدد السجادات السليمة حتى الحصول على ثلاث سجادات معيبة، فإننا نجد أن هذا المتغير العشوائي خاضع للتوزيع الحداني السالب بمعلمتين $n=3$ و $p=0.15$ ، ومن ثم الاحتمال المطلوب هو:

$$P(X=6) = \tilde{b}(6; 3, 0.15) = \binom{6+3-1}{6} (0.15)^3 (0.85)^6 = 0.0356$$

٣- يقوم شخص ما بقذف قطعة نقود متوازنة، فما هو احتمال أن يقوم بتكرار عملية القذف لتسع مرات حتى يحصل في المرة الأخيرة على الصورة الخامسة؟

الحل: ليكن X متغيراً عشوائياً راصداً لعدد الصور التي سيحصل عليها لدى تنفيذ عملية القذف، فعندئذ بسبب أن عملية قذف قطعة النقود هي تجارب برنولية مستقلة بعضها عن البعض الآخر باحتمال نجاح $p = 0.5$ ، فإننا نجد لهذا المتغير العشوائي X توزيعاً حدائياً سالباً بمعلمتين $n = 5$ و $p = 0.5$ ، ومن ثم الاحتمال المطلوب هو:

$$P(X = 9) = \tilde{b}(9; 5, 0.5) = \binom{9-1}{5-1} 0.5^5 (1-0.5)^{9-5} = 0.1367$$

٤- لدينا مستودع لإطارات (كفريات) السيارات جميعها مغلقة، وعادة يكون من بين هذه الإطارات كمية من الإطارات المعيبة (غير مطابقة للمواصفات) ولكنها غير مرئية، فإذا افترضنا أن نسبة الإطارات المعيبة في هذا المستودع تساوي 0.05، وأردنا أن نأخذ أربعة إطارات لسيارة، فما هو احتمال عثورنا على إطارين معينين قبل الحصول على الإطارات الأربع السليمة؟

الحل: في هذا المثال نلاحظ أن البحث عن إطارات للسيارة هي تجارب برنولية مستقلة بعضها عن البعض الآخر باحتمال نجاح $p = 0.95$ (لأن النجاح هنا هو الحصول على إطار سليم)، فلو أخذنا X متغيراً عشوائياً راصداً لعدد الإطارات السليمة حتى الحصول على إطارين معينين، فإننا نجد أن هذا المتغير العشوائي خاضع للتوزيع الحدائي السالب بمعلمتين $n = 4$ و $p = 0.95$ ، ومن ثم الاحتمال المطلوب هو:

$$P(X = 2) = \tilde{b}(2; 4, 0.95) = \binom{2+4-1}{2} (0.95)^4 (0.05)^2 = 0.0204$$

(٦، ١، ٦) التوزيع الهندسي Geometric Distribution

إن آلية عمل هذا المتغير العشوائي تنتج عن آلية عمل المتغير العشوائي السابق في حالة خاصة، وهو من المتغيرات العشوائية المهمة أيضاً، ويقدمه لنا التعريف الآتي.

(٦، ١، ٦، ١) تعريفه

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ يقال عن X إنه خاضع للتوزيع الهندسي بمعلمة $0 < p < 1$ إذا كان يأخذ قيماً صحيحة موجبة، وكان قانون توزيعه معطى من خلال العلاقة الآتية:

$$P(X = k) = p \cdot (1-p)^{k-1} \quad ; k \in \mathbb{N} \quad [6,6]$$

ونشير هنا إلى أن سبب تسمية هذا التوزيع بهذا الاسم يعود إلى نموذج الدالة المولدة الاحتمالية لهذا التوزيع حيث لها صيغة دالة هندسية (راجع فصل العزوم للاطلاع على مفهوم الدالة المولدة الاحتمالية).

(٦، ١، ٦، ٢) ملاحظات

١- سوف نستخدم الرمز $G(p)$ للدلالة على هذا التوزيع، وكذلك سنرمز بـ $g(k; p)$ للدلالة على قيمة الكتلة الاحتمالية لهذا المتغير العشوائي X ، أي إن:

$$g(k; p) \triangleq P(X = k)$$

٢- إن العلاقة الآتية تعد من العلاقات المميزة لهذا التوزيع:

$$P(X \geq \ell | X \geq k) = P(X \geq \ell - k) \quad ; \ell, k \in \mathbb{N}, \ell > k$$

ومعنى هذه العلاقة أن التوزيع الهندسي لا يمتلك ذاكرة Memoryless، بمعنى أن التوزيع الهندسي ينسى ما قد حصل له في الماضي، ولهذه العلاقة تطبيقات مهمة في مجال نظرية الخدمة وقطاعات عشوائية أخرى، وأما إثباتها فيتم على النحو الآتي:

من كون الحادث $\{\omega \in \Omega ; X(\omega) \geq k\}$ محتوياً في الحادث $\{\omega \in \Omega ; X(\omega) \geq \ell\}$ ، وباستخدام مفهوم الاحتمال الشرطي،

وملاحظة أن الاحتمال $P(X \geq s)$ يعني احتمال عدم حصولنا على أي نجاح خلال التكرارات المستقلة التي عددها s والذي قيمته تساوي $(1-p)^s$ ، فإنه يمكننا أن نكتب ما يلي:

$$P(X \geq \ell | X \geq k) = \frac{P(X \geq \ell, X \geq k)}{P(X \geq k)} = \frac{P(X \geq \ell)}{P(X \geq k)} = \frac{(1-p)^{\ell-1}}{(1-p)^{k-1}} = (1-p)^{\ell-k} = P(X \geq \ell-k)$$

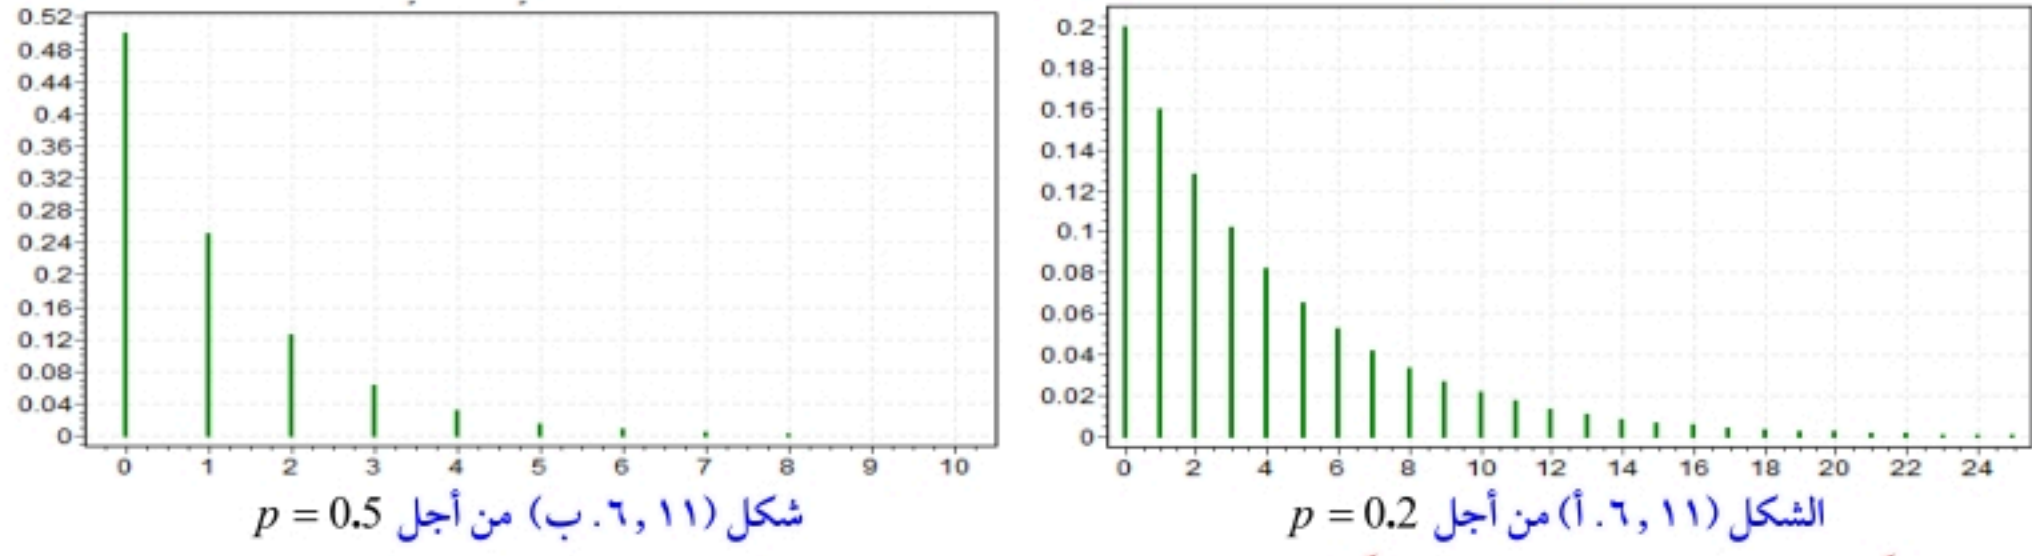
٣- يستخدم هذا النوع من المتغيرات العشوائية في التجارب العشوائية التي هي حيلة تكرارات مستقلة لتجارب برنولية باحتمال نجاح p ، علماً أن المتغير العشوائي X هنا يرصد عدد التجارب التي يجب تنفيذها حتى نحصل على أول نجاح. لاحظ هنا أن التوزيع الهندسي يمثل حالة خاصة من التوزيع الحداني السالب عندما تكون قيمة معلمته $n=1$.

٤- الجدولي الآتي يقدم لنا هذا المتغير العشوائي من أجل قيمة محددة للمعلمة p ، (سنأخذ $p=0.5$).

الجدول (٦، ٦)

i	1	2	3	4	5	6	sum
x_i قيم X	1	2	3	4	5	6	
$p_i = P(X = x_i)$	0.500	0.250	0.125	0.063	0.031	0.016	≈ 1

٥- سنقدم التمثيل البياني لهذا المتغير العشوائي من أجل قيمتين مختلفتين لـ p ، ويقدمهما الشكلان الآتيان:




فلاحظ هنا أن التوزيع ملتوي نحو اليمين، وأنه في الشكل (٦، ١١) نجد قيم الاحتمالات الموافقة لـ $10 < k$ صغيرة بحيث يصعب إيضاحها بالرسم.

٦- إن دالة توزيع هذا المتغير العشوائي نجدها باستخدام تعريف دالة توزيع متغير عشوائي متقطع، حيث لدينا:

$$F_X(x) = \sum_{\substack{k=1 \\ k \leq x}} p \cdot (1-p)^{k-1} \quad ; x \in \mathbb{R}$$

$$F_X(x) = \begin{cases} 0 & \text{for } x \leq 1 \\ 0.500 & \text{for } 1 < x \leq 2 \\ 0.750 & \text{for } 2 < x \leq 3 \\ 0.875 & \text{for } 3 < x \leq 4 \\ \vdots & \vdots \vdots \vdots \\ 1 & \text{for } x \rightarrow \infty \end{cases}$$

ومن أجل $p=0.5$ يكون لها العرض الآتي:



الشكل (٦، ١٢) دالة التوزيع الاحتمالية من أجل $p=0.5$.

(٦, ١, ٦, ٣) أمثلة

١- لدينا صندوق يحوي n كرة متماثلة تماماً وسجل على إحداها كلمة فائز، فلو قام شخص ما بعمليات سحب عشوائية لكرة من هذا الصندوق، ثم أعادها إلى الصندوق بحيث يتوقف عن تكرار عملية السحب لدى حصوله على الكرة التي كتب عليها فائز، فما هو احتمال أن يتوقف عن السحب بعد تنفيذ $\frac{n}{2}$ من عمليات السحب؟

الحل: في هذا المثال نلاحظ أن عمليات السحب هي تجارب برنولية مستقلة بعضها عن البعض الآخر باحتمال نجاح $p = \frac{1}{n}$ ، فلو كان متغيراً عشوائياً راصداً لعدد التجارب التي يجب تنفيذها حتى يحصل على الكرة التي كتب عليها كلمة فائز، لوجدنا أن هذا المتغير العشوائي خاضع للتوزيع الهندسي بمعلمة $p = \frac{1}{n}$ ، ومن ثم يكون لدينا:

$$P\left(X = \frac{n}{2}\right) = \frac{1}{n} \left(1 - \frac{1}{n}\right)^{\frac{n}{2}-1}$$

فلو أخذنا على سبيل المثال $n = 50$ لوجدنا أن احتمال الحصول على الكرة التي كتب عليها كلمة فائز بعد 25 عملية سحب يساوي:

$$P(X = 25) = g(25; 0.02) = \frac{1}{50} (1 - 0.02)^{24} = 0.0123$$

بينما لو أخذنا $n = 100$ لوجدنا أن احتمال الحصول على الكرة المذكورة آنفاً بعد 50 عملية سحب يساوي:

$$P(X = 50) = g(50; 0.01) = \frac{1}{100} (1 - 0.01)^{49} = 0.00061$$

حيث نلاحظ تضائل قيمة هذا الاحتمال كلما كبر عدد الكرات الموجودة في الصندوق.

٢- يقوم شخص ما بقذف قطعة نقود متوازنة حتى يحصل على صورة فيتوقف عن قذف القطعة، فعندئذ:

أ- ما هو احتمال أن يحصل على الصورة لأول مرة في عملية القذف السابعة؟

ب- إذا كان الشخص لم يحصل على صورة حتى القذفة الخامسة، فما هو احتمال أن يتابع في قذف القطعة لسبع مرات على الأقل؟

الحل: من أجل الطلب:

أ- ليكن X متغيراً عشوائياً راصداً لعدد عمليات قذف قطعة النقود حتى الحصول على الصور للمرة الأولى، فعندئذ بسبب أن عملية قذف قطعة النقود هي تجارب برنولية مستقلة بعضها عن بعض باحتمال نجاح $p = 0.5$ ، فإننا نجد أن لهذا المتغير العشوائي X توزيعاً هندسياً بمعلمة $p = 0.5$ ، ومن ثم الاحتمال المطلوب هو:

$$P(X = 7) = g(7; 0.5) = 0.5 (1 - 0.5)^6 = 0.0078$$

ب- إن الاحتمال المطلوب هو $P(X > 7 | X > 5)$ ، ومن ثم يكون لدينا:

$$\begin{aligned} P(X > 7 | X > 5) &= P(X > 7 - 5) = 1 - P(X \leq 2) = 1 - [P(X = 1) + P(X = 2)] \\ &= 1 - [g(1; 0.5) + g(2; 0.5)] = 1 - (0.5 + 0.25) = 0.25 \end{aligned}$$

ومن هذه النتيجة نلاحظ وضوح معنى أن هذا التوزيع لا يمتلك ذاكرة، وذلك لأن قيمة الاحتمال الذي حصلنا عليه يساوي أيضاً:

$$P(X = 2) = 0.5 (1 - 0.5) = 0.25$$

وكأن الشخص قد بدأ بقذف قطعة النقود لأول مرة بعد المرة الخامسة، وما كان من قذفات سابقة لا تأثير لها على قيمة الاحتمال، وكأن القذفات الخمس الأولى لم تنفذ أصلاً. **بيت من ذاكرة التوزيع.**

٣- لدينا جهاز يقوم بإجراء اختبارات لعينات صناعية وبشكل مستقل كل منها عن الآخر، فإذا كان احتمال إعطاء نتائج خاطئة

من قبل الجهاز 0.005، وأنَّ الجهاز سيوقف عن العمل عند الحصول على أول نتيجة خاطئة، فعندئذ:

أ- ما هو احتمال أن يتوقف الجهاز عن العمل بعد الانتهاء من اختبار العينة ذات الرقم 70؟

ب- إذا كان الجهاز لم يرتكب أي خطأ حتى الاختبار الخامس، فما هو احتمال أن يتابع في عمله حتى الاختبار التاسع على الأقل؟

الحل: من أجل الطلب:

أ- في هذا المثال نلاحظ أنَّ عملية اختبار العينات التي يقوم بها الجهاز هي تجارب برنولية مستقلة بعضها عن بعض باحتمال نجاح $p = 0.005$ ، حيث النجاح هنا هو حصولنا على نتيجة خاطئة من قبل الجهاز، فلو كان X متغيراً عشوائياً راصداً لعدد التجارب التي سيقوم الجهاز بتنفيذها حتى يقع الخطأ الأول من قبل الجهاز، فإننا نلاحظ أنَّ هذا المتغير العشوائي خاضع للتوزيع الهندسي بمعلمة $p = 0.005$ ، ومن ثمَّ الاحتمال المطلوب يساوي:

$$P(X = 70) = g(70; 0.005) = (0.005) (0.995)^{69} = 0.00354$$

ب- في هذه الحالة لدينا الاحتمال المطلوب هو $P(X > 9 | X > 5)$ ، ومن ثمَّ يكون لدينا:

$$\begin{aligned} P(X > 9 | X > 5) &= P(X > 9 - 5) = 1 - P(X \leq 4) \\ &= 1 - [P(X = 1) + P(X = 2) + P(X = 3) + P(X = 4)] \\ &= 1 - [g(1; 0.005) + g(2; 0.005) + g(3; 0.005) + g(4; 0.005)] \\ &= 1 - [0.005 + 0.004975 + 0.00495 + 0.00493] = 0.80145 \end{aligned}$$

٤- لنفترض أنَّ احتمال نجاح طالب في اختبار تحريري لمقرر معين يساوي 0.75، وأنَّ الاختبارات يمكن تكرارها بشكل مستقل

كل منها عن الآخر (بمعنى أنه لا يمكن للطالب أن يخمن طبيعة الأسئلة التي يمكن أن تقدم في الاختبار التالي للمقرر)، ولنقم بحساب:

أ- احتمال أن ينجح من الاختبار الأول.

ب- احتمال أن يتقدم الطالب للاختبار ثلاث مرات حتى يُحقِّق النجاح في هذا المقرر.

ج- احتمال أن يتقدم الطالب للاختبار لثلاث مرات على الأقل حتى يُحقِّق النجاح في هذا المقرر.

الحل: ليكن X متغيراً عشوائياً راصداً لعدد الاختبارات التي يتقدم بها الطالب حتى يُحقِّق النجاح في المقرر، فعندئذ بسبب أنَّ عملية تكرار الاختبارات هي تجارب برنولية مستقلة بعضها عن بعض باحتمال نجاح 0.75، فإننا نجد أنَّ لهذا المتغير العشوائي X توزيعاً هندسياً بمعلمة $p = 0.75$ ، ومن ثمَّ يكون لدينا من أجل الطلب:

أ- الاحتمال المطلوب هو:

$$P(X = 1) = g(1; 0.75) = 0.75 (1 - 0.75)^0 = 0.75$$

ب- الاحتمال المطلوب هو:

$$P(X = 3) = g(3; 0.75) = 0.75 (1 - 0.75)^2 = 0.047$$

ج- الاحتمال المطلوب هو:

$$\begin{aligned} P(X \geq 3) &= 1 - P(X \leq 2) = 1 - [P(X = 1) + P(X = 2)] \\ &= 1 - [g(1; 0.75) + g(2; 0.75)] \\ &= 1 - [0.75 (1 - 0.75)^0 + 0.75 (1 - 0.75)] = 0.0625 \end{aligned}$$

(٦, ١, ٧) التوزيع فوق الهندسي (أو الفوهندي) Hypergeometric Distribution:

إنَّ آلية عمل هذا المتغير العشوائي تختلف جذرياً عن آلية عمل المتغيرات العشوائية السابقة، وهو من المتغيرات العشوائية المهمة في مجال ضبط الجودة الإحصائي.

(٦, ١, ٧, ١) تعريفه

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ يُقال عن X إنه خاضع للتوزيع فوق الهندسي بمَعالم M, n و $N \geq n$ مع $N \geq M$ و $N > M$ ، إذا كان X يأخذ قيماً صحيحة غير سالبة، وقانون توزيعه مُعطى من خلال العلاقة الآتية:

$$P(X = k) = \binom{M}{k} \cdot \binom{N-M}{n-k} \cdot \binom{N}{n}^{-1} \quad [6,7]$$

علماً أنَّ $\max\{0, n - M + N\} \leq k \leq \min\{n, M\}$.

نشير هنا إلى أنَّ سبب تسمية هذا التوزيع بهذا الاسم يعود إلى نموذج الدالة المولدة الاحتمالية لهذا التوزيع حيث لها صيغة دالة فوق هندسية.

(٦, ١, ٧, ٢) ملاحظة

١- سوف نستخدم الرمز $H(N, M, n)$ للدلالة على توزيع هذا المتغير العشوائي، وكذلك سنرمز بـ $h(k; N, M, n)$ للدلالة على قيمة الكتل الاحتمالية لـ X ، أي إنَّ $h(k; N, M, n) \triangleq P(X = k)$.


- ٢- يستخدم هذا النوع من المتغيرات العشوائية في اختبارات ضبط الجودة الإحصائي وللقيم n, M, N و k الأدوار الآتية:
- القيمة N تمثل حجم المجتمع الإحصائي.
 - القيمة M تمثل عدد النجاحات في المجتمع الإحصائي.
 - القيمة n تمثل حجم العينة.
 - القيمة k تمثل عدد النجاحات في العينة.

٣- لتوضيح العرض الجدولي لهذا المتغير العشوائي سنأخذ قيماً محدَّدة للمَعالم، فمن أجل $N = 10, M = 5, n = 5$ يكون لجدول توزيع هذا المتغير العشوائي العرض الآتي:

الجدول (٦, ٧).

i	1	2	3	4	5	6	sum
x_i قيم X	0	1	2	3	4	5	
$p_i = P(X = x_i)$	0.004	0.099	0.397	0.397	0.099	0.004	1

٤- التمثيل البياني لهذا المتغير العشوائي من أجل قيم مختلفة لـ N, M و n يقدمها الشكلين الآتيين:


الشكل (٦, ١٣) ب. من أجل $N = 10$ و $M = 5$ و $n = 5$ الشكل (٦, ١٣) أ. من أجل $N = 100$ و $M = 20$ و $n = 45$

٥- إن دالة توزيع هذا المتغير العشوائي نجدها باستخدام تعريف دالة توزيع متغير عشوائي متقطع، حيث لدينا:

$$F_X(x) = \sum_{\substack{k=0 \\ k < x}} \binom{M}{k} \cdot \binom{N-M}{n-k} \cdot \binom{N}{n}^{-1} ; \forall x \in \mathbb{R}$$

ومن أجل $N = 10$ و $M = 5$ و $n = 5$ يكون لها العرض الآتي:

$$F_X(x) = \begin{cases} 0 & \text{for } x \leq 0 \\ 0.004 & \text{for } 0 < x \leq 1 \\ 0.103 & \text{for } 1 < x \leq 2 \\ 0.500 & \text{for } 2 < x \leq 3 \\ 0.897 & \text{for } 3 < x \leq 4 \\ 0.996 & \text{for } 4 < x \leq 5 \\ 1 & \text{for } x > 5 \end{cases}$$



الشكل (٦، ١٤) دالة التوزيع الاحتمالية من أجل $N = 10$ و $M = 5$ و $n = 5$.

حيث نلاحظ صعوبة تعيين دالة التوزيع F_X من أجل القيم الكبيرة للوسطاء N, M و n . في الحقيقة تُعد العلاقة السابقة لدالة التوزيع الاحتمالية لهذا المتغير العشوائي هي أبسط صيغة لحساب الدالة F_X ، ولكن بذلت محاولات جادة في إيجاد صيغ تقريبية لحساب F_X اعتماداً على توزيعات متقطعة أو مستمرة، حيث سنستعرض بعضها في نهاية هذا الفصل (انظر تقارب التوزيعات).

(٦، ١، ٧، ٣) أمثلة

١- لدينا في جهاز إلكتروني يحوي عشرة دارات متكاملة منها دارتين معطلتين، قام أحد عمال الصيانة وبشكل عشوائي بإزالة ثلاث دارات من الجهاز، فإذا افترضنا أن لجميع الدارات النصيب نفسه في الاختيار، فما هو احتمال أن تكون الدارات المعطلة من بين الدارات التي تم إزالتها من الجهاز؟

الحل: بفرض أن X متغيراً عشوائياً راصداً لعدد الدارات المعطلة التي نحصل عليها نتيجة لعملية إزالة الدارات، فإننا نجد أن هذا المتغير العشوائي خاضع للتوزيع فوق الهندسي بمعالم $N = 10$ و $M = 2$ و $n = 3$ ، ومن ثم يكون الاحتمال المطلوب هو:

$$P(X = 2) = h(2; 10, 2, 3) = \binom{2}{2} \cdot \binom{8}{1} \cdot \binom{10}{3}^{-1} = 0.0667$$

٢- في مزرعة إبل يوجد 25 رأساً منها خمسة مغاير. قام صاحب المزرعة بأخذ عشرة منها عشوائياً وبيعها، فما هو احتمال أن يكون هناك ثلاثة على الأكثر من المغاير قد تم بيعها؟

الحل: ليكن X متغيراً عشوائياً راصداً لعدد المغاير التي مع الإبل المباعة، فعندئذ نجد أن هذا المتغير العشوائي خاضع للتوزيع فوق الهندسي بمعالم $N = 25$ و $M = 5$ و $n = 10$ ، وأما الاحتمال المطلوب فهو $P(X \leq 3)$ حيث لدينا:

$$\begin{aligned} P(X \leq 3) &= P(X = 0) + P(X = 1) + P(X = 2) + P(X = 3) \\ &= h(0; 10, 2, 3) + h(1; 10, 2, 3) + h(2; 10, 2, 3) + h(3; 10, 2, 3) \end{aligned}$$

وبالتعويض عن كل حد بما يساويه نحصل على العلاقة الآتية:

$$P(X \leq 3) = \sum_{i=0}^3 \binom{5}{i} \cdot \binom{20}{10-i} \cdot \binom{25}{10}^{-1} = 0.0565 + 0.2569 + 0.3854 + 0.2372 = 0.936$$

في الواقع إن إيجاد حلول مسائل تتعلق بالتوزيع فوق الهندسي ليس بالأمر اليسير دوماً، لا بل قد يكون بحاجة إلى تقنيات متقدمة لحلها، والمثال التالي يوضح لنا ذلك.

٣- في مستودع لمصنع إنتاج المصابيح الكهربائية يوجد 50000 مصباح من نوع معين (أي لجميع المصابيح النصيب نفسه في الاختيار) منها 500 مصباح معطل، فإذا قمنا بسحب عشوائي لـ 50 مصباحاً دفعةً واحدة، وأخضعنا كل مصباح من هذه الدفعة للاختبار، فما هو احتمال ظهور خمسة مصابيح معطلة خلال هذه الاختبارات؟

الحل: ليكن X متغيراً عشوائياً راصداً لعدد المصابيح المعطلة التي ستظهر لدينا خلال هذه الاختبارات، فعندئذ سيكون لهذا المتغير العشوائي توزيعاً فوق هندسي بمعالم $N = 50000$ ، $M = 500$ و $n = 50$ ، ومن ثم الاحتمال المطلوب هو $P(X = 5)$ حيث لدينا:

$$P(X = 5) = h(5; 50000, 500, 50) = \frac{\binom{500}{5} \cdot \binom{49500}{1995}}{\binom{50000}{50}}$$

وهنا نلاحظ الصعوبة البالغة لحساب التوافيق في كل من البسط والمقام، وحتى الحاسبات اليدوية البسيطة قد لا تستطيع تنفيذ العمليات الحسابية المطلوبة للحل. لذلك سنقدم في نهاية هذا الفصل آلية فعالة لحل مثل هذه المسائل.

(٦, ١, ٨) توزيع بواسون Poisson Distribution

يتعامل هذا المتغير العشوائي مع حوادث نادرة الوقوع (قدّم أحد نماذجه كمثال في الفصل السابق)، ولذلك سنلاحظ أن آلية عمله قد ترتبط بعمل متغيرات عشوائية سابقة، وهو من المتغيرات العشوائية المهمة في مجال نظرية الطوابير (Queuing theory) (وتكون أساساً لنظرية الخدمة Service theory) ونظرية الوثوقية Reliability theory، وقدّم هذا التوزيع لأول مرة (عام 1837) كحالة تقاربية للتوزيع الحداني من قبل الرياضياتي والفيزيائي الفرنسي بواسون (Siméon Denis Poisson (1781-1840).

(٦, ١, ٨, ١) تعريفه

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ يُقال عن X إنه خاضع لتوزيع بواسون بمعلمة $\lambda > 0$ إذا كان يأخذ قيم صحيحة غير سالبة، وقانون توزيعه معطى من خلال العلاقة الآتية:

$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}; k \in \mathbb{N}^0 \quad [6,8]$$

(٦, ١, ٨, ٢) ملاحظات

١- سوف نستخدم الرمز $P(\lambda)$ للدلالة على هذا التوزيع، وكذلك سنرمز بـ $p(k; \lambda)$ للدلالة على قيمة الكتل الاحتمالية لهذا المتغير العشوائي X ، أي إن $p(k; \lambda) \triangleq P(X = k)$.



٢- يستخدم هذا النوع من التوزيعات في حساب احتمالات لحوادث نادرة الوقوع، وفي نظرية الخدمة، وكذلك في نظرية الوثوقية، وفي دراسة توزيعات الجسيمات الدقيقة أيضاً.

٣- لتوضيح العرض الجدولي لهذا المتغير العشوائي سنأخذ للمعلمة λ القيمة $\lambda = 1.5$ ، فيكون لجدول توزيع هذا المتغير العشوائي العرض الآتي:

الجدول (٦, ٨).

i	1	2	3	4	5	6	sum
x_i قيم X	0	1	2	3	4	5	...
$p_i = P(X = x_i)$	0.223	0.335	0.251	0.126	0.047	0.014	≈ 1

وأما التمثيل البياني لهذا المتغير العشوائي من أجل قيم مختلفة لـ λ يقدمها الشكلين الآتين:


الشكل (٦, ١٥) ب) من أجل $\lambda = 1.5$ الشكل (٦, ١٥) أ) من أجل $\lambda = 50$

٤- إن دالة توزيع هذا المتغير العشوائي نجدها باستخدام تعريف دالة توزيع متغير عشوائي متقطع، حيث لدينا:

$$F_X(x) = \sum_{k=0; k \leq x}^{\infty} \frac{\lambda^k}{k!} e^{-\lambda} \quad ; x \in \mathbb{R}$$

ومن أجل $\lambda = 1.5$ يكون لها العرض الآتي:

$$F_X(x) = \begin{cases} 0 & \text{for } x \leq 0 \\ 0.2231 & \text{for } 0 < x \leq 1 \\ 0.5577 & \text{for } 1 < x \leq 2 \\ 0.8088 & \text{for } 2 < x \leq 3 \\ 0.9344 & \text{for } 3 < x \leq 4 \\ \vdots & \vdots \vdots \vdots \\ 1 & \text{for } x \rightarrow \infty \end{cases}$$

الشكل (٦, ١٦) دالة التوزيع الاحتمالية من أجل $\lambda = 1.5$.

يلاحظ هنا الصعوبة في حساب الدالة F_X من أجل القيم الكبيرة للوسيط λ ، ولكن يمكن حسابها باستخدام ما يسمى بـ

تكامل غاما الناقص والذي له الصيغة $\Gamma_k = \frac{1}{k!} \int_{\lambda}^{+\infty} e^{-t} t^k dt$ حيث يبرهن على صحة العلاقة الآتية:

$$F_X(x) = \frac{1}{[x]!} \int_{\lambda}^{+\infty} e^{-t} t^{[x]} dt$$

(٦, ١, ٨, ٣) أمثلة

١- إذا علمت أن عدد الأهداف التي يمكن لمنتخب كرة قدم أن يسجلها في مباريات واحدة يخضع لتوزيع بواسون بمعلمة

$\lambda = 1$ (الوحدة لـ λ هنا هي الهدف)، فعندئذ:

أ- ما هو احتمال أن يسجل هذا الفريق أربعة أهداف في مباراة مقبلة؟

ب- ما هو احتمال أن يسجل هذا الفريق هدفًا واحدًا على الأقل في مباراة مقبلة؟

الحل: بفرض أن X متغيراً عشوائياً راصداً لعدد الأهداف التي سيسجلها الفريق في مباراة مقبلة، فعندئذ سيكون X خاضعاً لتوزيع بواسون بمعلمة $\lambda = 1$ ، ومن ثم يكون لدينا:

أ- احتمال أن يسجل هذا الفريق أربعة أهداف في مباراة مقبلة هو:

$$P(X = 4) = p(4; 1) = \frac{1^4}{4!} e^{-1} = 0.01533$$

ب- احتمال أن يسجل هذا الفريق هدف واحد على الأقل في مباراة مقبلة هو:

$$P(X \geq 1) = 1 - P(X < 1) = 1 - P(X = 0) = 1 - p(0; 1) = 1 - 0.369 = 0.631$$

٢- إذا علمت أن عدد الزوار خلال دقيقة واحدة إلى مخدّم الويب يتبع توزيع بواسون بمعلمة $\lambda = 7$ (الوحدة لـ λ هنا هي زائر)، فعندئذ:

- أ- ما هو احتمال وجود ثلاثة زوار على الأكثر خلال فترة دقيقة ما من زمن عمل المخدّم؟
 ب- ما هو احتمال أن تمر دقيقة من زمن عمل المخدّم دون دخول أي زائر عليه؟

الحل: بفرض أن X متغيراً عشوائياً راصداً لعدد الزوار الداخلين إلى خدمة الويب في كل دقيقة، فعندئذ سيكون X خاضعاً لتوزيع بواسون بمعلمة $\lambda = 7$ ، ومن ثم يكون لدينا من أجل الطلب:

أ- الاحتمال المطلوب هو:

$$\begin{aligned} P(X \leq 3) &= P(X = 0) + P(X = 1) + P(X = 2) + P(X = 3) \\ &= p(0; 7) + p(1; 7) + p(2; 7) + p(3; 7) \\ &= 0.0009 + 0.0064 + 0.0223 + 0.0521 = 0.0817 \end{aligned}$$

ب- الاحتمال المطلوب هو:

$$P(X = 0) = p(0; 7) = 0.0009$$

٣- عند تقاطع معيّن لطريقين رئيسيين وجد أن عدد الحوادث المرورية التي تحصل عنده أسبوعياً تتوزع بواسونياً بمعلمة $\lambda = 0.5$ ، ولنقم باستخدام التوزيع البواسوني لحساب:

- أ- احتمال وقوع خمسة حوادث عند هذا التقاطع خلال أسبوع ما؟
 ب- احتمال وقوع حادثين على الأقل عند هذا التقاطع خلال أسبوع ما؟

الحل: من أجل الطلب:

أ- إن الاحتمال المطلوب هو:

$$P(X = 5) = p(5; 0.5) = 0.000158$$

ب- إن الاحتمال المطلوب هو الآتي:

$$\begin{aligned} P(X \geq 2) &= 1 - P(X < 2) = 1 - [P(X = 0) + P(X = 1)] \\ &= 1 - [p(0; 0.5) + p(1; 0.5)] = 1 - [0.6065 + 0.3033] = 0.0902 \end{aligned}$$

تطبيقات أخرى على استخدام التوزيع البواسوني نجدها بعد فقرة تقارب التوزيعات الاحتمالية في نهاية هذا الفصل. سنكتفي بهذا القدر من المعلومات حول بعض المتغيرات العشوائية المتقطعة حيث يوجد الكثير منها، ومن يود الاطلاع على المزيد يمكنه الرجوع إلى بعض المراجع المذكورة في نهاية هذا الكتاب.

(٦,٢) توزيعات احتمالية مستمرة

Continuous Probability Distributions

فيما يلي سنقدم بعض التوزيعات الاحتمالية المستمرة الشهيرة التي سيكون لها دور مهم في مجال العشوائيات، وسنبداً هذه التوزيعات بالتوزيع الآتي.


(٦,٢,١) التوزيع المنتظم المستمر Continuous Uniform Distribution:

يعد هذا التوزيع من أهم وأكثر المتغيرات العشوائية المستخدمة في توليد الأرقام العشوائية.

(٦,٢,١,١) تعريفه

ليكن X متغيراً عشوائياً مستمراً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ يُقال عن X إنه خاضع للتوزيع المنتظم المستمر على فترة محدودة $[a, b] \subset \mathbb{R}$ إذا كانت دالة كثافته الاحتمالية f_X معطاة من خلال العلاقة الآتية من أجل كل $x \in \mathbb{R}$:

$$f_X(x) = \begin{cases} 0 & \text{for } x < a \\ \frac{1}{b-a} & \text{for } a \leq x \leq b \\ 0 & \text{for } x > b \end{cases}$$



الشكل (٦, ١٧)

ولرسمها البياني الشكل السابق حيث نلاحظ أن الدالة f_X تعاني من نقطتي انقطاع (من النوع الأول) في كل من النقطتين a و b ، ومن ثم ستكون دالة توزيع هذا المتغير العشوائي غير قابلة للمفاضلة في كل من النقطتين a و b .


(٦,٢,١,٢) ملاحظات

- ١- سوف نستخدم الرمز $U([a, b])$ للدلالة على هذا التوزيع.
- ٢- من أهم استخدامات هذا المتغير العشوائي توليد الأرقام العشوائية.
- ٣- باستخدام تعريف دالة التوزيع الاحتمالية لمتغير عشوائي مستمر يكون لدالة توزيع هذا المتغير العشوائي العرض الآتي من أجل كل $x \in \mathbb{R}$:

$$F_X(x) = \frac{1}{b-a} \int_{-\infty}^x \mathbf{I}_{[a,b]}(t) dt = \frac{x-a}{b-a} \mathbf{I}_{(a,b)}(x) + \mathbf{I}_{(b,\infty)}(x)$$

ويمكن كتابتها وفقاً للصيغ الشرطية على النحو الآتي أيضاً:

$$F_X(x) = \begin{cases} 0 & \text{for } x \leq a \\ \frac{x-a}{b-a} & \text{for } a < x \leq b \\ 1 & \text{for } x > b \end{cases}$$



الشكل (٦, ١٨) الرسم البياني لدالة التوزيع الاحتمالية.

(٦, ٢, ١, ٣) أمثلة

١- لنفترض أن المدة الزمنية التي تحتاجها إقامة الأفراح أو الأتراح في استراحة ما تخضع للتوزيع المنتظم على الفترة $[0, 5]$ (مقدرة بالساعات)، فعندئذ لنحسب احتمال أن تُشغل هذه الاستراحة لمدة لا تتجاوز أربع ساعات.

الحل: من أجل ذلك ليكن X متغيراً عشوائياً راصداً لزمن انشغال الاستراحة، فعندئذ يكون لدالة الكثافة الاحتمالية لتوزيع زمن انشغال الاستراحة العرض الآتي:

$$f_X(x) = \begin{cases} \frac{1}{5} & \text{for } 0 \leq x \leq 5 \\ 0 & \text{otherwise} \end{cases}$$

ومن ثم يكون الاحتمال المطلوب هو:

$$P(X \leq 4) = \int_0^4 \frac{1}{5} dx = \frac{1}{5} \int_0^4 dx = \frac{4}{5} = 0.8$$

٢- في مصنع لإنتاج السجاد يوجد آلة لنسج السجاد بحيث يخضع زمن إنتاجها (مقدرة بالدقيقة) للتوزيع المنتظم على الفترة $[30, 45]$ ، فإذا أخذنا سجادة ما من المنتج لهذا المصنع فما هو احتمال أن يكون الزمن الذي استغرقه إنتاج هذه السجادة لا يتجاوز 35 دقيقة؟

الحل: من أجل ذلك ليكن X متغيراً عشوائياً راصداً للمدة الزمنية اللازمة لإنتاج سجادة من قبل الآلة، فعندئذ يكون لدالة الكثافة الاحتمالية لتوزيع زمن الإنتاج العرض الآتي:

$$f_X(x) = \begin{cases} \frac{1}{15} & \text{for } 30 \leq x \leq 45 \\ 0 & \text{otherwise} \end{cases}$$

وأما الاحتمال المطلوب فهو $P(X \leq 35)$ ، وقيمته تساوي:

$$P(X \leq 35) = \int_{30}^{35} \frac{1}{15} dx = \frac{1}{15} \int_{30}^{35} dx = \frac{5}{15} = 0.\bar{3}$$

(٦, ٢, ٢) التوزيع الأسّي Exponential Distribution


يعدّ هذا المتغير العشوائي من المتغيرات العشوائية المهمة جداً في مجال دراسة نظرية الوثوقية ونظرية الطوابير، ويستخدم في مجال توليد الأرقام العشوائية أيضاً.

(٦, ٢, ٢, ١) تعريفه

ليكن X متغيراً عشوائياً مستمراً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ يقال عن X إنه خاضع للتوزيع الأسّي بمعلمة $0 < \lambda$ إذا كانت دالة كثافته الاحتمالية f_X معطاة من خلال العلاقة الآتية:

$$f_X(x) = \lambda e^{-\lambda x} \cdot \mathbf{I}_{[0, +\infty)}(x) \quad ; \quad \forall x \in \mathbb{R} \quad [6, 10]$$

والرسم البياني لدالة الكثافة الاحتمالية لهذا المتغير العشوائي يقدمها الشكلين الآتيين من أجل قيمتين مختلفتين لـ λ .

الشكل (١٩، ٦.ب) من أجل $\lambda = 0.5, \lambda = 0.3$ الشكل (١٩، ٦.أ) من أجل $\lambda = 3, \lambda = 1$

فلاحظ أن الدالة f_X تعاني من نقطة انقطاع (من النوع الأول) في المبدأ، ومن ثم ستكون دالة توزيع هذا المتغير العشوائي غير قابلة للمفاضلة في المبدأ.

(٦، ٢، ٢، ٢) ملاحظات

- ١- سوف نستخدم الرمز $Ex(\lambda)$ للدلالة على هذا التوزيع.
- ٢- يستخدم هذا النوع من المتغيرات العشوائية في نظرية الوثوقية ونظرية الخدمة، وكذلك في توليد الأرقام العشوائية.
- ٣- من الخصائص المهمة لهذا التوزيع أنه لا يمتلك ذاكرة (كما هو الحال لدى التوزيع الهندسي)، ويعبر عن ذلك بالعلاقة الآتية:

$$P(X \geq x+t | X \geq t) = P(X \geq x) \quad ; x, t > 0 \quad [6,11]$$

ولإثباتها سنستخدم مفهوم الاحتمال الشرطي حيث يمكننا أن نكتب الآتي.

بسبب أن $\{\omega \in \Omega ; X(\omega) > x+t\} \supseteq \{\omega \in \Omega ; X(\omega) > t\}$ فإنه سيكون لدينا:


$$\begin{aligned} P(X \geq x+t | X \geq t) &= \frac{P(X \geq x+t, X \geq t)}{P(X \geq t)} = \frac{P(X \geq x+t)}{P(X \geq t)} = \frac{1-P(X < x+t)}{1-P(X < t)} \\ &= \frac{e^{-\lambda(x+t)}}{e^{-\lambda t}} = e^{-\lambda x} = P(X \geq x) \end{aligned}$$

- ٤- باستخدام تعريف دالة التوزيع الاحتمالية لمتغير عشوائي مستمر يكون لدالة توزيع هذا المتغير العشوائي العرض الآتي:

$$F_X(x) = \int_{-\infty}^x \lambda e^{-\lambda t} I_{[0, +\infty)}(t) dt = \int_0^x \lambda e^{-\lambda t} dt = (1 - e^{-\lambda x}) I_{[0, +\infty)}(x) \quad ; \forall x \in \mathbb{R}$$

والتي يمكن كتابتها من أجل كل $x \in \mathbb{R}$ على النحو الآتي أيضاً:

$$F_X(x) = \begin{cases} 0 & \text{for } x \leq 0 \\ 1 - e^{-\lambda x} & \text{for } x > 0 \end{cases}$$

الشكل (٢٠، ٦). الرسم البياني لدالة التوزيع الاحتمالية من أجل $\lambda = 3, \lambda = 1, \lambda = 0.5$.

(٦, ٢, ٢, ٣) أمثلة

- ١- إذا علمت أن الوقت اللازم لإصلاح سيارة في ورشة صيانة هو متغير عشوائي أسّي بمعلمة $\lambda = 1.5$ ساعة، فعندئذ:
- أ- لنحسب احتمال ألا يستغرق وقت إصلاح سيارة في هذه الورشة أكثر من ثلاث ساعات.
- ب- لنحسب احتمال أن يستغرق إصلاح سيارة في هذه الورشة أكثر من أربع ساعات.
- ج- ما هو احتمال أن يستغرق وقت إصلاح السيارة أكثر من أربع ساعات علماً أن عامل الإصلاح بدأ عمله في إصلاح السيارة منذ ثلاث ساعات؟

الحل: من أجل الطلب (أ) لدينا الاحتمال المطلوب هو:

$$\begin{aligned} P(X \leq 3) &= P(X < 3) = F_X(3) \\ &= \int_{-\infty}^3 \lambda e^{-\lambda t} \mathbf{I}_{[0, +\infty)}(t) dt = \int_0^3 1.5 e^{-1.5t} dt \\ &= 1 - e^{-1.5(3)} = 0.98889 \end{aligned}$$

ب- من أجل الطلب (ب) لدينا الاحتمال المطلوب هو:

$$\begin{aligned} P(X > 4) &= 1 - P(X \leq 4) = 1 - P(X < 4) = 1 - F_X(4) \\ &= 1 - [1 - e^{-1.5(4)}] = 1 - 0.9975 = 0.0025 \end{aligned}$$

- ج- من أجل الطلب (ج) لدينا الاحتمال المطلوب هو $P(X > 4 | X > 3)$ ، وبما أن التوزيع الأسّي لا يمتلك ذاكرة فإنه سيكون لدينا:

$$\begin{aligned} P(X > 1+3 | X > 3) &= P(X > 1) \\ &= 1 - F_X(1) = 1 - 0.777 = 0.223 \end{aligned}$$

- ٢- لنفترض أن أجهزة تحتوي على نوع معين من العناصر الإلكترونية التي يمكن أن تتعطل خلال فترة زمنية T (مقدرة بالسنوات). فإذا علمنا أن التوزيع الاحتمالي للمتغير العشوائي T هو توزيع أسّي بمعلمة $\lambda = 1$ سنة، وأنه قد تم تثبيت خمسة عناصر في أجهزة مختلفة وبشكل مستقل بعضها عن البعض الآخر، فما هو احتمال أن يبقى على الأقل عنصرين يعملان حتى نهاية السنوات الخمس القادمة؟

الحل: من أجل ذلك سناخذ X متغيراً عشوائياً راصداً لعدد الأجهزة التي ستبقى تعمل حتى نهاية السنوات الخمس القادمة، فعندئذ سيكون لهذا المتغير العشوائي توزيعاً حدائياً بمعلمتين $n = 5$ و $p = ?$ يجب حسابه من التوزيع الاحتمالي للمتغير العشوائي T ، وأما الاحتمال المطلوب فهو $P(X \geq 2)$. حيث لدينا:

$$\begin{aligned} p &= P(T > 5) = 1 - P(T \leq 5) = 1 - P(T < 5) \\ &= 1 - F_T(5) = 1 - (1 - e^{-5}) = 1 - 0.993 \approx 0.007 \end{aligned}$$

ومنه يكون الاحتمال المطلوب هو:

$$\begin{aligned} P(X \geq 2) &= 1 - P(X < 2) = 1 - [P(X = 0) + P(X = 1)] \\ &= 1 - [\mathbf{b}(0; 0.007) + \mathbf{b}(1; 0.007)] \\ &= 1 - [0.965 + 0.033] = 1 - 0.998 = 0.002 \end{aligned}$$

Normal Distribution (٦, ٢, ٣) **التوزيع الطبيعي**

إنَّ التوزيع الطبيعي (أو ما يُعرف باسم التوزيع الغاوسي **Gaussian Distribution** أيضاً) يُعدّ من أكثر التوزيعات الاحتمالية أهمية وفائدة في حقل الإحصاء بأكمله، وهذا التوزيع يصف العديد من الظواهر التي تحدث في الطبيعة، والصناعة، والبحوث العلمية على حدّ سواء، فعلى سبيل المثال:

- وجد أن الكثير من الظواهر في الطبيعة تتوزع احتمالياً وفقاً لهذا التوزيع، فمنها ظاهرة التجمهر أمام موضع مُحدّد في منطقة **مفتوحة**، حيث يتجمهر الناس أمام منصّة في منطقة مفتوحة، ومن الطبيعي أن يفضل معظمهم الجلوس (أو الوقوف) قريباً من المنصّة بقدر المستطاع، فيكون لهم التوضع الموضح في الرسم الآتي (في معظم الحالات).



ولهذا السبب دعي التوزيع المقدم آنفاً باسم "التوزيع الطبيعي"، وذلك لأنه نتج عن سلوك فطري لدى الناس.

- القياسات الفيزيائية في مجالات عديدة كقياسات الأجزاء الصناعية يكون لتوزيعها الاحتمالي (وفي كثير من الأحيان) تقريب جيد مع التوزيع الطبيعي.
- الأخطاء المرتكبة لدى أخذ القياسات العملية يمكن تقريبها بشكل جيد من التوزيع الطبيعي، وهناك أمثلة كثيرة أخرى لا مجال لذكرها في هذه العجالة من التقديم.

لقد كان الرياضياتي الفرنسي **موافير** (1667-1754) Abraham de Moivre أول من وضع المعادلة الرياضية للمنحنى الطبيعي في عام 1733، ولكن جاء بعده الرياضياتي **الألماني غاوس** (1777-1855) Johann Carl Friedrich Gauss ليستنتج المعادلة الرياضية للمنحنى الطبيعي من دراسة الأخطاء في القياسات المتكررة للكمية نفسها، ولهذا أطلق على هذا التوزيع اسم **توزيع غاوس** تكريماً له، وبسبب الأهمية الكبيرة لهذا التوزيع سوف نستفيض قليلاً في تقديمه.

(٦, ٢, ٣, ١) تعريفه


ليكن X متغيراً عشوائياً مستمراً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ يُقال عن X إنه خاضع للتوزيع الطبيعي بمعلمتين $\mu \in \mathbb{R}$ و $0 < \sigma$ إذا كانت دالة كثافته الاحتمالية f_X مُعطاة من خلال العلاقة الآتية:

$$f_X(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right] \quad ; \forall x \in \mathbb{R} \quad [6,12-a]$$


وفي الحالة الخاصة عندما تكون $\mu = 0$ و $\sigma = 1$ فإنه يصبح للعلاقة السابقة العرض الآتي:

$$f_X(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \quad ; \forall x \in \mathbb{R} \quad [6,12-b]$$

ويُقال حينئذ إنَّ المتغير العشوائي X خاضع للتوزيع الطبيعي المعياري Standard Normal Distribution ويرمز لدالة الكثافته الاحتمالية الموافقة له بـ $\phi(x)$ ، ويصبح منحنى هذه الدالة متناظراً بالنسبة إلى المحور OY كما هو واضح في الشكلين الآتين الذين يقدمان لنا الرسم البياني لهما من أجل قيم مختلفة لـ $\mu \in \mathbb{R}$ و $0 < \sigma$:



الشكل (٢١، أ) دالة كثافته الاحتمالية للتوزيع الطبيعي من أجل $\sigma = 1$ للجميع $\mu = -1$ و $\mu = 0$ و $\mu = 2$



الشكل (٢١، ب) دالة كثافته الاحتمالية للتوزيع الطبيعي من أجل $\mu = 0$ للجميع $\sigma = 0.5$ و $\sigma = 1$ و $\sigma = 2$

فلاحظ هنا أن الدالة f_X مستمرة على \mathbb{R} ، ولذلك ستكون دالة التوزيع الاحتمالية لهذا التوزيع مستمرة وقابلة للمفاضلة عند كل نقطة x من \mathbb{R} . كما نلاحظ أن تغير قيمة μ توافق الذروة لمنحنى دالة الكثافة الاحتمالية، ويؤدي إلى انسحاب منحنى دالة الكثافة الاحتمالية لهذا التوزيع يمنة أو يسرة وذلك بحسب القيمة التي تأخذها هذه المعلمة، وأن تغير قيمة σ يؤدي إلى تدبب أو انبساط منحنى دالة الكثافة الاحتمالية لهذا التوزيع وذلك بحسب القيمة التي تأخذها هذه المعلمة، وهنا نشير إلى أنه يقال عن منحنى دالة كثافته الاحتمالية للتوزيع الطبيعي إنه منبسط إذا كان $\sigma > 1$ ، وفي حال كان $\sigma < 1$ فعندئذ يقال عن هذا المنحنى إنه مدبب، وأما إذا كان $\sigma = 1$ فعندئذ يقال عن هذا المنحنى إنه معتدل التفلطح. لذلك ينظر في هذه الحالة إلى شكل منحنى دالة كثافته الاحتمالية للتوزيع الطبيعي على أنه مقياس الاعتدال لأشكال التوزيعات (من حيث التدبب والانبساط) كما سبق وذكرنا ذلك في الفصل الثاني.

(٢، ٣، ٢، ٦) ملاحظات



- ١- يرمز للتوزيع الطبيعي ذي المعلمتين μ و σ بالرمز $N(\mu, \sigma)$ (وبعض المراجع تستخدم الرمز $N(\mu, \sigma^2)$ للدلالة عليه).
- ٢- عندما يكون المتغير العشوائي X خاضع للتوزيع الطبيعي المعياري فإنه يرمز لدالة توزيعه بالرمز $\Phi(x)$ عوضاً عن $F_X(x)$ (ولو أن هذا الرمز الأخير يستخدم بين الحين والآخر).
- ٣- يستخدم هذا النوع من المتغيرات العشوائية في قطاعات علمية كثيرة جداً منها على سبيل المثال لا الحصر: توزيع حساب الأخطاء، الاختبارات الإحصائية، توليد الأرقام العشوائية و...
- ٤- إن لدالة التوزيع الطبيعي ذي المعلمتين μ و σ العرض الآتي:

$$F_X(x) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{(t-\mu)^2}{2\sigma^2}} dt \quad ; \forall x \in \mathbb{R}$$

وأما من أجل الحالة الخاصة عندما يكون المتغير العشوائي X خاضعاً للتوزيع الطبيعي المعياري فإنه يصبح لدينا:

$$\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt \quad ; \forall x \in \mathbb{R}$$

ومن أجل قيمتين مختلفتين لـ μ و σ نجد لهذه الدالة الرسمين البيانيين الآتيين:



الشكل (٦, ٢٢) ب) دالة اللتوزيع الطبيعي من أجل $\mu = 2$ وللجميع $\sigma = 2$.


الشكل (٦, ٢٢) أ) دالة اللتوزيع الطبيعي المعياري

نشير هنا إلى أنه يوجد في آخر هذا الكتاب جدولان لقيم هذه الدالة، أحدهما من أجل القيم الموجبة لـ z مبتدأة من الصفر وبتزايد يساوي 0.01، والآخر من أجل القيم السالبة لـ z مبتدأة من الصفر وبتناقص يساوي 0.01، وهذه القيم تمكننا من حساب احتمالات متعلقة بمتغير عشوائي طبيعي معياري، فعلى سبيل المثال لو أخذنا Z متغيراً عشوائياً بحيث $Z \sim N(0,1)$ ، فعندئذ يكون لدينا $P(Z < 0.35) = \Phi(0.35) = 0.6368$ ، ونجدها من جدول القيم الموجبة لهذا التوزيع كما يوضحها العرض الآتي:

الجدول (٦, ٩)

Z	0.00	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09
0.0	0.5000	0.5040	0.5080	0.5120	0.5160	0.5199	0.5239	0.5279	0.5319	0.5359
0.1	0.5398	0.5438	0.5478	0.5517	0.5557	0.5596	0.5636	0.5675	0.5714	0.5753
0.2	0.5793	0.5832	0.5871	0.5910	0.5948	0.5987	0.6026	0.6064	0.6103	0.6141
0.3	0.6179	0.6217	0.6255	0.6293	0.6331	0.6368	0.6406	0.6443	0.6480	0.6517
0.4	0.6554	0.6591	0.6628	0.6664	0.6700	0.6736	0.6772	0.6808	0.6844	0.6879
0.5	0.6915	0.6950	0.6985	0.7019	0.7054	0.7088	0.7123	0.7157	0.7190	0.7224

وتمثلها المساحة المظللة في الشكل الآتي:



الشكل (٦, ٢٣)

سنرمز بـ z_α للقيمة على المحور الأفقي OX التي يقع على يسارها وتحت منحنى دالة الكثافة الاحتمالية للتوزيع الطبيعي

المعياري مساحة قدرها α ، فعلى سبيل المثال لدينا في الشكل السابق:

$$z_{0.6368} = 0.35$$

كما يمكن لهذه القيم التي في الجدول أن تساعدنا في تعيين القيمة z لمتغير عشوائي طبيعي معياري Z إذا كانت قيمة الاحتمال $P(Z < z)$ معلومة، فعلى سبيل المثال لو أخذنا Z متغيراً عشوائياً بحيث $Z \sim N(0,1)$ ، وكان لدينا:


$$P(Z < z) = \Phi(z) = 0.6664$$

فعندئذ نجد من جدول التوزيع الطبيعي المعياري (القسم الخاص بالقيم الموجبة لأن 0.6664 موجبة) أن قيمة z تساوي 0.43، وذلك من خلال جمع قيمتي z الرأسية والأفقية المقابلتين للقيمة 0.6664 وهما 0.4+0.03، والشكل الآتي يوضح لنا ذلك:

الجدول (٦، ١٠)

Z	0.00	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09
0.0	0.5000	0.5040	0.5080	0.5120	0.5160	0.5199	0.5239	0.5279	0.5319	0.5359
0.1	0.5398	0.5438	0.5478	0.5517	0.5557	0.5596	0.5636	0.5675	0.5714	0.5753
0.2	0.5793	0.5832	0.5871	0.5910	0.5948	0.5987	0.6026	0.6064	0.6103	0.6141
0.3	0.6179	0.6217	0.6255	0.6293	0.6331	0.6368	0.6406	0.6443	0.6480	0.6517
0.4	0.6554	0.6591	0.6628	0.6664	0.6700	0.6736	0.6772	0.6808	0.6844	0.6879
0.5	0.6915	0.6950	0.6985	0.7019	0.7054	0.7088	0.7123	0.7157	0.7190	0.7224

نشير هنا إلى أنه في حال كانت قيمة الاحتمال التي لدينا غير موجودة في جدول التوزيع الطبيعي المعياري فإننا نستعين بالأقرب إليها لتعيين قيمة z المقابلة، وفي حال كانت قيمة هذا الاحتمال واقعة بالوسط تماماً بين قيمتين z_1 و z_2 فإننا سنأخذ قيمة المتوسط لـ z_1 و z_2 كقيمة لـ z . كما يمكن استنتاجها بشكل تقريبي مقبول باستخدام منحني دالة التوزيع الاحتمالية $\Phi(z)$ (في حال توفرها لدينا)، فعلى سبيل المثال نجد من أجل القيمة السابقة $P(Z < z) = 0.6664 \approx 0.67$ أنه لدينا من العرض البياني لدالة التوزيع الطبيعي المعياري، أن قيمة z هي 0.43، (انظر الشكل الآتي):



شكل (٦، ٢٤).

وكما يوضح لنا الشكل السابق أنه إذا كان $P(Z < z) = \Phi(z) = 0.2$ فإن قيمة z المقابلة تساوي تقريباً -0.8، وبالفعل إذا رجعنا إلى جدول التوزيع الطبيعي المعياري (القسم الخاص بالقيم السالبة لـ z) فإننا سنجد من أجل $\Phi(z) = 0.2005$ أن قيمة z المقابلة هي

$$z = -0.84$$

نشير هنا إلى أنه توجد جداول عديدة ومتنوعة في طريقة عرضها والدقة المستخدمة فيها، وقد استخدمنا هذا الجدول لبساطته وسهولة التعامل معه، ومن أجل الجداول المقدمة سنضع $\Phi(z) = 1$ من أجل قيم $z \geq 3.50$ ، وكذلك سنضع $\Phi(z) = 0$ من أجل قيم $z \leq -3.50$.

الآن وبطريقة مماثلة لما سبق يمكننا تنفيذ نماذج عديدة من الحساب الاحتمالي باستخدام جدول التوزيع الطبيعي المعياري، ومنها على سبيل المثال الاحتمالات الآتية:

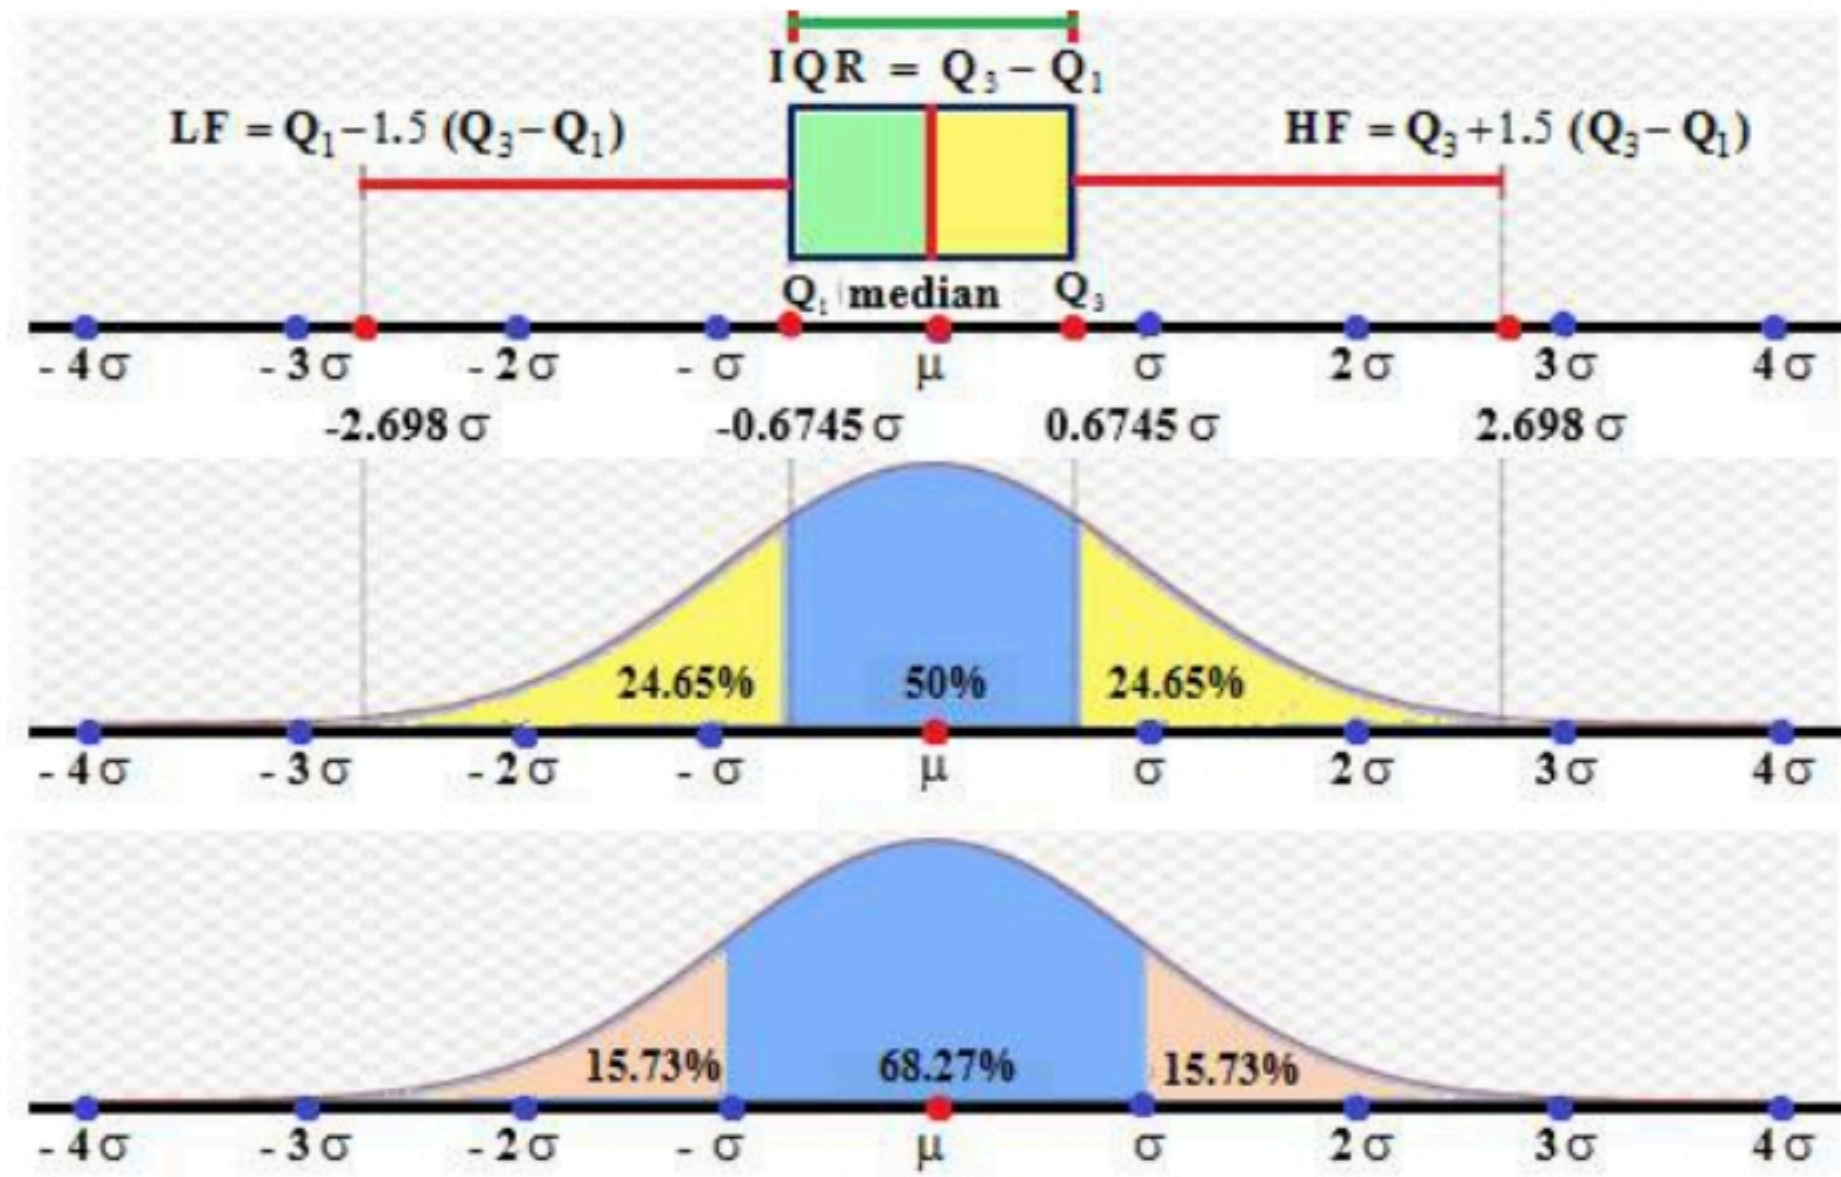
$$P(Z \geq 0.71) = 1 - P(Z < 0.71) = 1 - 0.7611 = 0.2389$$

$$P(-4.10 \leq Z < 1.03) = P(-4.10 < Z \leq 1.03) = P(-4.10 < Z < 1.03) \\ = \Phi(1.03) - \Phi(-4.10) \approx 0.8485 - 0.00 = 0.8485$$

أما إذا كان متغير عشوائي X يخضع للتوزيع الطبيعي غير المعياري، فعندئذ يمكن حساب احتمالات متعلقة بهذا المتغير العشوائي من خلال عملية استيعاره Standardization (أي تحويله إلى متغير عشوائي طبيعي معياري)، فلو كان لدينا على سبيل المثال $X \sim N(\mu, \sigma)$ وطلب منا حساب $P(X < x)$ ، فإننا نقوم بعملية استيعار للمتغير العشوائي X من خلال وضع $Z := \frac{X - \mu}{\sigma}$ ، وبفرض أن $z := \frac{x - \mu}{\sigma}$ فتنتج لدينا العلاقة الآتية:

$$P(X < x) = P\left(\frac{X - \mu}{\sigma} < \frac{x - \mu}{\sigma}\right) = P(Z < z) = \Phi(z)$$

وأما القيمة $\Phi(z)$ فإنها تستخرج من جدول التوزيع الطبيعي المعياري كما نوهنا عن ذلك سابقاً. أخيراً نقدّم العرض الآتي الذي يظهر لنا توزيع البيانات الناتجة عن تجربة تتبع التوزيع الطبيعي $N(\mu, \sigma)$ (أو لبيانات مولدة بوساطة التوزيع الطبيعي $N(\mu, \sigma)$) وعلاقتها بالانحرافات المعيارية والقيم المتطرفة بصغرها وكبرها (انظر الشكل الآتي واستنتج التفسيرات حسب ما ورد في الفصل الثاني من هذا الكتاب).



الشكل (٢٥، ١.٦)

علماً أنَّ الربعيات Q_1 ، Q_2 و Q_3 تحسب من أجل التوزيع الطبيعي $N(\mu, \sigma)$ وفقاً للعلاقات الآتية:
١- قيمة الربعي الأول Q_1 توافق تلك القيمة x التي تكون فيها العلاقة الآتية محققة:

$$\frac{1}{4} = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{(t-\mu)^2}{2\sigma^2}} dt$$

$$0.25 = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt \Rightarrow x = -0.6745$$

ومن أجل من أجل التوزيع الطبيعي المعياري يكون لدينا

٢- قيمة الربعي الثاني (الوسيط) $Q_2 = \tilde{x}$ توافق تلك القيمة x التي تكون فيها العلاقة الآتية محققة:

$$\frac{1}{2} = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{(t-\mu)^2}{2\sigma^2}} dt$$

$$0.5 = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt \Rightarrow x = 0$$

ومن أجل من أجل التوزيع الطبيعي المعياري يكون لدينا

٣- من أجل الربعي الثالث Q_3 قيمته توافق تلك القيمة x التي تكون فيها العلاقة الآتية محققة:

$$\frac{3}{4} = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{(t-\mu)^2}{2\sigma^2}} dt$$

$$0.75 = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt \Rightarrow x = 0.6745$$

ومن أجل من أجل التوزيع الطبيعي المعياري يكون لدينا

(٦، ٢، ٣، ٣) أمثلة


١- لنأخذ $X \sim N(10, 3)$ ، ولنقم بحساب قيمة الاحتمال $P(7 \leq X < 16)$ ، ومن ثم تقديم التفسير الهندسي لما يحدث نتيجة لعملية الاستيعار.

الحل: من أجل ذلك لنقم أولاً باستيعار المتغير العشوائي المعطى X فنجد الآتي:

$$P(7 \leq X < 16) = P\left(\frac{7-10}{3} \leq \frac{X-10}{3} < \frac{16-10}{3}\right) = P(-1 \leq Z < 2)$$

$$= \Phi(2) - \Phi(-1) = 0.9772 - 0.1587 = 0.8185$$

والآن لو أمعنا النظر في الشكل الآتي لمعرفة ما الذي حدث للمساحة المشغولة من قبل المتغير العشوائي المعطى X بعد عملية الاستيعار، فإننا نلاحظ تغير شكل المساحة دون تغير قيمتها.



الشكل (٦، ٢٥) ب.

٢- لنأخذ $X \sim N(-0.5, 0.5)$ ، فإذا كان لهذا المتغير العشوائي قيمة بين -0.55 و 1.01 فما هما القيمتين اللتين تقع بينهما قيمة المتغير العشوائي Z الناتج عن عملية الاستيعار X ؟

الحل: من أجل ذلك لنقم باستيعار المتغير العشوائي المعطى X فنجد الآتي:

$$P(-0.55 \leq X < 1.01) = P\left(\frac{-0.55 - (-0.5)}{0.5} \leq \frac{X - (-0.5)}{0.5} < \frac{1.01 - (-0.5)}{0.5}\right) = P(-0.10 \leq Z < 3.02)$$

وهكذا نجد القيمتين اللتين تقع بينهما قيمة المتغير العشوائي Z الناتج عن عملية الاستيعار X هما -0.10 و 3.02 .

٣- لنأخذ $X \sim N(-1, 1.5)$ ، ولنقم بحساب قيمة الاحتمال $P(-0.55 \leq X < 1.01)$.

الحل: من أجل ذلك لنقم أولاً باستيعار المتغير العشوائي المعطى X فنجد الآتي:

$$P(-0.55 \leq X < 1.01) = P\left(\frac{-0.55 - (-1)}{1.5} \leq \frac{X - (-1)}{1.5} < \frac{1.01 - (-1)}{1.5}\right)$$

وبوضع $Z = (X + 1)/1.5$ يصبح لدينا:

$$P(-0.55 \leq X < 1.01) = P(0.30 \leq Z < 1.34) = \Phi(1.34) - \Phi(0.30) = 0.9099 - 0.6179 = 0.2920$$

٤- لنأخذ $X \sim N(1, 2)$ ، ولنقم بحساب الاحتمالات الآتية:

$$\text{a) } P(X < 1.53) \quad \text{b) } P(X > -2.74) \quad \text{c) } P(-2.74 < X \leq 1.53)$$

الحل: بما أن المتغير العشوائي المعطى X ليس معيارياً فإننا سنقوم باستيعاره في كل حالة من الحالات الثلاث المطلوب حساب

احتمالها، فنجد من أجل الطلب:

(a) أنه باستخدام جدول التوزيع الطبيعي المعياري لتعيين قيمة الاحتمال المطلوب ما يلي:

$$P(X < 1.53) = P\left(\frac{X - 1}{2} < \frac{1.53 - 1}{2}\right) = P\left(Z < 0.2650\right) = \Phi(0.2650) = 0.6045$$

(b) أنه وبشكل مماثل لما قمنا به في الطلب السابق، سيكون لدينا:

$$\begin{aligned} P(X > -2.74) &= 1 - P(X \leq -2.74) = 1 - P\left(\frac{X - 1}{2} \leq \frac{-2.74 - 1}{2}\right) \\ &= 1 - P(Z < -1.8700) = 1 - \Phi(-1.8700) = 1 - 0.0307 = 0.9693 \end{aligned}$$

(c) أنه وبشكل مماثل لما قمنا به في الطلبين السابقين، سيكون لدينا:

$$\begin{aligned} P(-2.74 \leq X < 1.53) &= P\left(\frac{-2.74 - 1}{2} \leq \frac{X - 1}{2} < \frac{1.53 - 1}{2}\right) = P\left(\frac{-2.74 - 1}{2} \leq \frac{X - 1}{2} < \frac{1.53 - 1}{2}\right) \\ &= 1 - P(-1.8700 \leq Z < 0.2650) = \Phi(0.2650) - \Phi(-1.8700) \\ &= 0.6045 - 0.0307 = 0.5738 \end{aligned}$$

٥- لنأخذ $X \sim N(-2, 1.5)$ ، ولنقم بتعيين قيمة x في كل من الحالات الآتية:

$$\text{a) } P(X < x) = 0.9750 \quad \text{b) } P(X > x) = 0.8549$$

الحل: بما أن المتغير العشوائي المعطى X ليس معيارياً فإننا سنقوم باستيعاره في كل حالة من الحالتين المطلوب حساب احتماله،

ف نجد من أجل الطلب:

(a) أنه باستخدام جدول التوزيع الطبيعي المعياري لتعيين قيمة الاحتمال المطلوب ما يلي:

$$P(X < x) = P\left(\frac{X - (-2)}{1.5} < \frac{x - (-2)}{1.5}\right) = P(Z < z) = \Phi(z) = 0.9750$$

ومن جدول التوزيع الطبيعي المعياري نجد أن قيمة z الموافقة للاحتمال 0.9750 هي 1.96، ومن ثم نحسب قيمة x المطلوبة على النحو الآتي:

$$z = \frac{x + 2}{1.5} = 1.96 \Rightarrow x = 2.94 - 2 = 0.94$$

(b) أنه وبشكل مماثل لما قمنا به في الطلب السابق سيكون لدينا:

$$\begin{aligned} P(X > x) &= 1 - P(X \leq x) = 1 - P(X < x) \\ &= 1 - P\left(\frac{X - (-2)}{1.5} < \frac{x - (-2)}{1.5}\right) \\ &= 1 - P(Z < z) = 1 - \Phi(z) = 0.0505 \end{aligned}$$

ومن هذه العلاقة الأخيرة نجد أن $P(Z < z) = 1 - 0.0505 = 0.9495$ ، ومن جدول التوزيع الطبيعي المعياري نجد القيمة z الموافقة للاحتمال 0.9495 هي 1.64، ومنه يكون لدينا $z = \frac{x + 2}{1.5} = 1.64$ ، ومن ثم نجد أن $x = 2.46 - 2 = 0.46$.

من الأسماء المرتبطة بالتوزيع الطبيعي ما يعرف باسم **التوزيع الطبيعي اللوغارتمي** Lognormal Distribution، وهو توزيع يعتمد في تعريفه على التوزيع الطبيعي، حيث يقال عن متغير عشوائي Y إنه خاضع للتوزيع الطبيعي اللوغارتمي إذا كانت دالة كثافته الاحتمالية f_Y معطاة من خلال العلاقة الآتية:

$$f_Y(y) = \frac{1}{\sqrt{2\pi} \sigma y} \exp\left[-\frac{(\ln y - \mu)^2}{2\sigma^2}\right] \cdot I_{(0, \infty)}(y)$$

فلاحظ أن لهذا التوزيع معلمتين هما $0 \leq \mu$ و $0 < \sigma$ يدعيان المتوسط والانحراف المعياري لهذا التوزيع أيضاً (ولذلك سنرمز لهذا التوزيع بـ $LN(\mu, \sigma)$). أما الرسم البياني لدالة كثافته الاحتمالية f_Y فلها العرض في الشكل الآتي (٢٦، ٦. أ)، حيث نلاحظ أن هنا أن قيمة الانحراف المعياري هي المسؤولة عن انسحاب ذروة دالة الكثافة الاحتمالية يمناً ويساراً، فكلما كبرت قيمة σ فإن ذلك سيؤدي إلى ازدياد أكبر لذروة دالة الكثافة الاحتمالية نحو اليسار. كما يلاحظ أنه بفرض لـ X توزيع طبيعي $N(\mu, \sigma)$ فإن المتغير العشوائي Y الموصوف أعلاه له العرض $Y = \ln X$.


في الحالة الخاصة عندما تكون $\mu = 0$ و $\sigma = 1$ فإنه يصبح للعلاقة السابقة العرض الآتي:

$$f_Y(x) = \frac{1}{\sqrt{2\pi} y} \exp\left[-\frac{(\ln x)^2}{2}\right] \cdot I_{(0, \infty)}(x)$$


و أما دالة التوزيع الاحتمالية لـ Y فلها العرض الآتي من أجل كل $0 < x$:

$$F_Y(x) = \Phi\left(\frac{\ln(x) - \mu}{\sigma}\right) = \frac{1}{\sigma_X \sqrt{2\pi}} \int_{-\infty}^{\ln x} e^{-\frac{(t - \mu_X)^2}{2\sigma_X^2}} dt$$

ولرسمها البياني العرض الآتي في الشكل (٢٦، ٦. ب).



الشكل (٢٦، ٦. ب)



الشكل (٢٦، ٦. أ)

لهذا التوزيع تطبيقات كثيرة في مجالات علمية متعددة منها العلوم الهندسية والفيزيائية والكيميائية والاجتماعية، حيث يلعب التوزيع اللوغاريتمي دوراً مهماً في التصميم الاحتمالي لأن القيم السالبة لبعض الظواهر تكون في بعض الأحيان مستحيلة مادياً. من استخداماته نمذجة فشل الاجهاد، ومعدلات الفشل، وظواهر أخرى تنطوي على مجموعة كبيرة من البيانات.

(٦، ٢، ٤) توزيع ستودنت Student Distribution

فيما يلي ستتعرف على توزيع له أهمية خاصة في مجال الإحصاء الرياضي، وعلى وجه الخصوص في الدراسات التي تتعلق بتقديرات واختبارات ذات صلة بمتوسط مجتمع إحصائي. لقد اكتشف الكيميائي والرياضي الإنكليزي **غوسيت** William Sealy Gosset (1876–1937) هذا التوزيع عام 1908 في أثناء عمله في مصنع غينيس للـجعة، وفي ذلك الحين لم يكن يسمح مصنع غينيس لموظفيه بنشر أعمالهم، ولذلك استخدم غوسيت اسماً مستعاراً هو "**طالب** Student"، وبناءً على ذلك عرف هذا التوزيع باسم توزيع ستودنت (كما أنه يُعرف باسم توزيع **t-Distribution** أيضاً).


(٦، ٢، ٤، ١) تعريفه

ليكن X متغيراً عشوائياً مستمراً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ يُقال عن X إنه خاضع لتوزيع **ستودنت** بمعلّمة $n \in \mathbb{N}$ تُدعى **عدد درجات الحرية** Degrees of Freedom إذا كانت دالة كثافته الاحتمالية f_X مُعطاة من خلال العلاقة الآتية:

$$f_X(x) = \frac{\Gamma\left(\frac{n+1}{2}\right) \cdot \left(1 + \frac{x^2}{n}\right)^{-\frac{n+1}{2}}}{\sqrt{n\pi} \cdot \Gamma\left(\frac{n}{2}\right)}; \forall x \in \mathbb{R} \quad [6,13]$$

علماً أنّ $\Gamma(x)$ ترمز لدالة غاما عند القيمة x (انظر الملحق A).

إنّ الرسم البياني لدالة الكثافة الاحتمالية لتوزيع ستودنت نجده من أجل قيم مختلفة لعدد درجات الحرية n كما في الشكل الآتي:



الشكل (٢٧، ٦.١)

(٢، ٤، ٢، ٦) ملاحظات

١- سنرمز لتوزيع هذا المتغير العشوائي بـ $T(n)$ ، وأما دالة كثافته الاحتمالية فسوف نرمز لها بـ $\tau(x; n)$.


٢- في الحالة الخاصة عندما $n = 1$ يصبح لدالة الكثافة الاحتمالية f_X العرض الآتي:

$$f_X(x) = \frac{1}{\pi(1+x^2)} \quad ; \forall x \in \mathbb{R} \quad [6,14-a]$$

وهذه الدالة الأخيرة هي دالة الكثافة الاحتمالية لما يُعرف باسم **توزيع كوشي** Cauchy Distribution ذو المعلمتين $\mu = 0$ و $\lambda = 1$ (نسبة إلى الرياضي الفرنسي كوشي (Augustin-Louis Cauchy (1789-1857)). علماً أن الصيغة العامة لدالة الكثافة الاحتمالية لتوزيع كوشي ذي المعلمتين $\mu \in \mathbb{R}$ و $0 < \lambda$ هي:

$$f_X(x) = \frac{\lambda}{\pi(\lambda^2 + (x - \mu)^2)} \quad ; \forall x \in \mathbb{R} \quad [6,14-b]$$

وقيم μ هنا تلعب دور معامل الانسحاب لمنحنى دالة الكثافة الاحتمالية يمّنة أو يسرة فوق المحور Ox في حين أن قيم λ تلعب دور معامل التدبب للأعلى أو الانبساط نحو الأسفل لمنحنى دالة الكثافة الاحتمالية (انظر الشكل الآتي).



الشكل (٢٧، ٦.ب)

وسنرمز لهذا التوزيع بـ $C(\mu, \lambda)$ ، وأما دالة كثافته الاحتمالية فسوف نرمز لها بـ $C(x; \mu, \lambda)$.

٣- إن توزيع ستودنت يُستخدم في اختبارات عديدة منها اختبارات القيم الوسطى، وفي تحليل الانحدار.

٤- باستخدام تعريف دالة التوزيع الاحتمالية لمتغير عشوائي مستمر يكون لدالة توزيع هذا المتغير العشوائي العرض الآتي:

$$F_X(x) = \int_{-\infty}^x \frac{\Gamma\left(\frac{n+1}{2}\right) \cdot \left(1 + \frac{t^2}{n}\right)^{-\frac{n+1}{2}}}{\sqrt{n\pi} \Gamma\left(\frac{n}{2}\right)} dt \quad ; \forall x \in \mathbb{R}$$


والتي يمكن صياغتها باستخدام الدالة فوق الهندسية $H(x)$ على النحو الآتي أيضاً:

$$F_X(x) = \frac{1}{2} + x \cdot \Gamma\left(\frac{n+1}{2}\right) \frac{{}_2H\left(\frac{1}{2}, \frac{n+1}{2}; \frac{3}{2}; -\frac{x^2}{n}\right)}{\sqrt{n\pi} \Gamma\left(\frac{n}{2}\right)}$$

نشير هنا إلى أنه من الصعب جداً (كما هو واضح) التعامل مع هذه الصيغة في الحسابات، ولذلك تُستخدم جداول لحساب قيم دالة التوزيع السابقة، وقد قدم أحد هذه الجداول في آخر هذا الكتاب، وهذا الجدول يعطينا قيماً لهذه الدالة من أجل قيم مختلفة لدرجات الحرية n وقيماً محدّدة للاحتتمالات التي تأخذ عندها دالة التوزيع هذه القيم، ومنها 0.90 0.95 0.975 0.99 0.995 0.999، وكذلك توجد نماذج أخرى من الجداول تقدّم قيماً للاحتتمالات من قبيل 0.001 0.005 0.01 0.025 0.05 0.10، فعلى سبيل المثال من أجل $n = 5$ و $P(X < x) = 0.975$ فإن قيمة x الموافقة لهذا الاحتمال تساوي 2.571، بمعنى أن x هنا هي تلك القيمة على المحور oX التي يقع على يسارها وتحت منحنى دالة الكثافة الاحتمالية لتوزيع ستودنت ذي الـ 5 درجات حرية، مساحة قدرها 0.975 (الشكل الآتي يوضح لنا ذلك). كذلك نجد من أجل $n = 8$ أن $P(X < 3.355) = 0.995$.

الجدول (١١، ٦)

α	0.90	0.95	0.975	0.99	0.995	0.999
n						
1.	3.078	6.314	12.706	31.821	63.657	318.313
2.	1.886	2.920	4.303	6.965	9.925	22.327
3.	1.638	2.353	3.182	4.541	5.841	10.215
4.	1.533	2.132	2.776	3.747	4.604	7.173
5.	1.476	2.015	2.571	3.365	4.032	5.893
6.	1.440	1.943	2.447	3.143	3.707	5.208
7.	1.415	1.895	2.365	2.998	3.499	4.782
8.	1.397	1.860	2.306	2.896	3.355	4.499
9.	1.383	1.833	2.262	2.821	3.250	4.296




الشكل (٢٧، ٦ ج)

٥- سوف نرمز بـ $t_{\alpha}^{[n]}$ للقيمة t الواقعة على المحور الأفقي oX التي يقع على يسارها وتحت منحنى الكثافة الاحتمالية $\tau(x; n)$ مساحة قدرها α (قيمة هذه المساحة تساوي $P(X < x)$)، فعلى سبيل المثال من أجل $n = 13$ و $\alpha = 0.90$ يكون لدينا $t_{0.90}^{[13]} = 1.350$ أي إن $P(X < 1.350) = 0.90$.


٦- لو أمعنا النظر في جدول التوزيع الطبيعي المعياري

وجداول توزيع ستودنت لوجدنا أنه من أجل قيم درجات الحرية $32 \leq n$

يصبح الفرق بين قيم دالتي التوزيع الاحتمالية لهذين التوزيعين ضئيلاً (انظر الشكل الآتي) حيث يلاحظ تقارب شكل دالة توزيع ستودنت من دالة التوزيع الطبيعي المعياري مع تزايد قيم عدد درجات الحرية n . كما يعرض الشكلين الآتين الوضع النسبي لمنحنيات دوال الكثافة الاحتمالية، وكذلك دوال التوزيع الاحتمالية، لتوزيع ستودنت لدى تزايد قيم عدد درجات الحرية n ، ومقارنتها مع التوزيع الطبيعي.



الشكل (٦, ٢٨) ب) دوال كثافة احتمالية لتوزيع ستودنت



الشكل (٦, ٢٨) أ) دوال توزيع احتمالية لتوزيع ستودنت

فعلى سبيل المثال لو أخذنا $X \sim N(0,1)$ فإننا سنجد $P(X < 0.96) = 0.8315$ ، ولقد اخترنا القيمة $x = 0.96$ لأن الفرق بين قيم دوال التوزيع عند هذه النقطة كبيرة نسبياً (انظر الشكل السابق)، فلو قمنا باستخدام الحاسوب لحساب المقادير الآتية المتعلقة بقيم التوزيعات $T(n)$ (لأن بعض قيمها عند النقطة المذكورة آنفاً قد تقع خارج محتويات الجدول المخصص لهذا التوزيع) فإننا سنجد ما يلي:

الجدول (٦, ١٢)

من أجل	لدينا		من أجل	لدينا
$X \sim T(1)$	$P(X < 0.96) = 0.7435$		$X \sim T(50)$	$P(X < 0.96) = 0.8292$
$X \sim T(2)$	$P(X < 0.96) = 0.7808$		$X \sim T(75)$	$P(X < 0.96) = 0.8299$
$X \sim T(5)$	$P(X < 0.96) = 0.8094$		$X \sim T(100)$	$P(X < 0.96) = 0.8303$
$X \sim T(25)$	$P(X < 0.96) = 0.8269$		$X \sim T(1000)$	$P(X < 0.96) = 0.8314$

وهكذا نلاحظ تساؤل قيمة الفرق بينهما كلما كبرت قيمة n ، ولهذا السبب يقوم البعض باستخدام جدول التوزيع الطبيعي لحساب احتمالات تتعلق بتوزيع ستودنت عندما يكون عدد درجات الحرية $32 \leq n$ ، وهناك آخرون يستخدمون هذه العملية من أجل قيم $27 \leq n$ ، ولكن يفضل دوماً استخدام جدول توزيع ستودنت في حال توفره عند القيم المطلوب حساب احتمالاتها. بخصوص الأمثلة والتطبيقات على هذا التوزيع سوف نقدمها لاحقاً في البحوث الإحصائية لدى تقديم فترات الثقة واختبار الفرضيات الإحصائية.

(٦, ٢, ٥) توزيع كاي مربع Chi Square Distribution

إن توزيع كاي مربع يعدّ من التوزيعات المهمة التي لها دور مميّز في مجال الإحصاء الرياضي أيضاً، وعلى وجه الخصوص في الدراسات التي تتعلق بتقدير واختبار فرضية إحصائية ذات صلة بتباين مجتمع طبيعي، وكذلك في مجال اختبار جودة التوفيق لتوزيع، وبعض الاختبارات غير المعلمية الأخرى التي سنقدم بعضها منها لاحقاً في الفصول التابعة للإحصاء الرياضي.

(١, ٢, ٥, ٦) تعريفه

ليكن X متغيراً عشوائياً مستمراً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ يُقال عن X إنه خاضع لتوزيع **كاي مربع** بمعلمة $n \in \mathbb{N}$ تدعى **عدد درجات الحرية** للتوزيع، إذا كانت دالة كثافته الاحتمالية f_X معطاة من خلال العلاقة الآتية:

$$f_X(x) := \left(\Gamma\left(\frac{n}{2}\right) \right)^{-1} \left(\frac{1}{2} \right)^{\frac{n}{2}} x^{\frac{n}{2}-1} e^{-\frac{x}{2}} \cdot \mathbf{I}_{(0, \infty)}(x) \quad ; \forall x \in \mathbb{R} \quad [6,15]$$


والشكل الآتي (٦, ٢٨ أ) يعرض لنا رسوماً بيانية لهذه الدالة من أجل قيم مختلفة لعدد درجات الحرية n .

(٢, ٢, ٥, ٦) ملاحظات


١- سنرمز بـ $\chi^2(n)$ لتوزيع هذا المتغير العشوائي، وبـ $\chi^2(x; n)$ لدالة كثافته الاحتمالية.

٢- سنرمز بـ χ^2_{α} للقيمة على المحور الأفقي OX والتي يقع على يسارها وتحت منحنى دالة الكثافة الاحتمالية لهذا المتغير العشوائي مساحة قدرها α (انظر الشكل (٦, ٢٩ ب) حيث يوضح لنا ذلك).

٣- يستخدم هذا النوع من المتغيرات العشوائية في اختبارات إحصائية عديدة منها اختبار فرضية إحصائية ذات صلة بتباين مجتمع طبيعى، وكذلك في مجال اختبارات لفرضيات غير معلّمة مثل اختبار جودة التوفيق لتوزيع ما، واختبارات التجانس، واختبارات الاستقلال بين الظواهر.




شكل (٦, ٢٩ ب)

شكل (٦, ٢٩ أ) دالة الكثافة الاحتمالية من أجل قيم مختلفة لـ n .

٤- باستخدام تعريف دالة التوزيع الاحتمالية لمتغير عشوائي مستمر يكون لدالة توزيع هذا المتغير العشوائي العرض الآتي.

$$F_X(x) = \int_{-\infty}^x \frac{\left(\frac{1}{2}\right)^{\frac{n}{2}}}{\Gamma\left(\frac{n}{2}\right)} t^{\frac{n}{2}-1} e^{-\frac{t}{2}} \mathbf{I}_{(0, +\infty)}(t) dt \quad ; \forall x \in \mathbb{R}$$

والشكل الآتي يقدم رسماً بياني من أجل قيم مختلفة لعدد درجات الحرية n .



الشكل (٦, ٣٠)

نشير هنا أيضاً إلى أنه من الصعب جداً التعامل مع هذه الصيغة في الحسابات، وكذلك يصعب عرضها من خلال دوال بسيطة، فعلى سبيل المثال يمكن تقديمها من خلال العلاقة الآتية:

$$F_X(x) = \frac{\gamma\left(\frac{n}{2}, \frac{x}{2}\right)}{\Gamma\left(\frac{n}{2}\right)} = G\left(\frac{n}{2}, \frac{x}{2}\right)$$

علماً أن $\gamma(.,.)$ في الصيغة السابقة هي دالة غاما غير المكتملة الدنيا وأما $G(.,.)$ فإنها ترمز إلى دالة غاما المعممة (وهي نوعان خاصان من الدوال). لذلك تُستخدم جداول خاصة لحساب قيم دالة التوزيع السابقة، وقد قُدم أحد هذه الجداول في آخر هذا الكتاب، وهذا الجدول يعطينا قيماً لهذه الدالة من أجل قيم مختلفة لدرجات الحرية n وقيم محددة للاحتتمالات التي تأخذ عندها دالة التوزيع هذه القيم، ومنها:

$$0.005 \quad 0.025 \quad 0.05 \quad 0.90 \quad 0.95 \quad 0.975 \quad 0.99 \quad 0.995$$

فعلى سبيل المثال:

أ- من أجل $n = 5$ و $P(X < x) = 0.975$ فإن قيمة x الموافقة لهذا الاحتمال تساوي 2.571.

ب- من أجل $n = 8$ فإن $P(X < 3.355) = 0.995$ تساوي 0.995.

ج- من أجل $n = 4$ لدينا $P(X < 48.602) = 0.95$.

علماً أن عملية استخراج القيم x من جدول توزيع كاي مربع تتم بطريقة مماثلة لتلك التي استخدمت في استخراج القيم من جدول توزيع ستودنت السابق شرحها.

٥- إذا كانت $n \leq 32$ فعندئذ يمكن استخدام جدول التوزيع الطبيعي عوضاً عن جدول توزيع كاي مربع من خلال حساب المقدار $\chi_{\alpha}^{[n]}$ وفقاً للعلاقة الآتية:

$$\chi_{\alpha}^{[n]} = \frac{\left(\bar{z}_{\alpha} + \sqrt{2n-1}\right)^2}{2} \quad [6,15]$$

فعلى سبيل المثال لو أخذنا $\alpha = 0.975$ فإننا سنجد من جدول التوزيع الطبيعي المعياري أن $\bar{z}_{0.975} = 1.96$ ، وكذلك لدينا من أجل $n = 50$ و $n = 100$ على الترتيب ما يلي:

$$\frac{\left(\bar{z}_{0.975} + \sqrt{100-1}\right)^2}{2} = 71.903 \quad \text{and} \quad \frac{\left(\bar{z}_{0.975} + \sqrt{200-1}\right)^2}{2} = 129.07$$

ومن جدول توزيع كاي مربع نجد $\chi_{0.975}^{[50]} = 71.420$ و $\chi_{0.975}^{[100]} = 129.65$ حيث يلاحظ أن الفارق في كلا الحالتين قريب من النصف.

(٦, ٢, ٦) توزيع فيشر Fisher distribution

إن توزيع فيشر يعدّ من التوزيعات الاحتمالية المهمة جداً في الدراسات الإحصائية أيضاً، وقد كان الإحصائي الإنكليزي فيشر Sir Ronald Aylmer Fisher (1890–1962) هو أول من وصف هذا التوزيع عام 1924 في عمل علمي قام بنشره آنذاك.

(٦, ٢, ٦, ١) تعريفه

ليكن X متغيراً عشوائياً مستمراً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ يقال عن X إنه خاضع لتوزيع فيشر (أو توزيع F)


بمعلمتين $n, m \in \mathbb{N}$ تدعيان **درجة حرية البسط والمقام** على الترتيب، إذا كانت دالة كثافته الاحتمالية معطاة من خلال العلاقة الآتية:

$$f_X(x) := \frac{\left(\frac{m}{n}\right)^{\frac{m}{2}}}{\beta\left(\frac{m}{2}, \frac{n}{2}\right)} x^{\frac{m}{2}-1} \left(1 + \frac{mx}{n}\right)^{-\frac{m+n}{2}} \mathbf{I}_{(0,\infty)}(x) \quad ; \forall x \in \mathbb{R} \quad [6,16-a]$$

علماً أنَّ $\beta(p, q)$ هي قيمة **دالة بيتا** عند $p, q \in \mathbb{R}$ ، أو أن تُكتب بالشكل الآتي أيضاً:

$$f_X(x) = \frac{\Gamma\left(\frac{m+n}{2}\right) m^{\frac{m}{2}} n^{\frac{n}{2}}}{\Gamma\left(\frac{m}{2}\right) \Gamma\left(\frac{n}{2}\right)} \frac{x^{\frac{m}{2}-1}}{(n+mx)^{\frac{m+n}{2}}} \mathbf{I}_{(0,\infty)}(x) \quad ; \forall x \in \mathbb{R} \quad [6,16-b]$$

إنَّ شكل الرسم البياني لدالة الكثافة الاحتمالية لهذا التوزيع يتغير بتغير قيم الوسطاء m و n ، والشكل الآتي يقدم لنا عروضاً من أجل قيم مختلفة لكل من m و n .




الشكل (٦، ٣١) (١.٦، ٣١)

(٦، ٢، ٦، ٢) ملاحظات


- ١- سنرمز لدالة توزيع هذا المتغير العشوائي بـ $F(m; n)$ في حين سنرمز بـ $f(x; m, n)$ لدالة كثافته الاحتمالية.
- ٢- إنَّ هذا النوع من المتغيرات العشوائية له استخدامات عديدة منها اختبارات مقارنة التباين للمجتمعات الإحصائية، وفي تحليل التباين، وكذلك في تحليل التباين (تمام التباين).
- ٣- سنرمز بـ $f_{\alpha}^{[m, n]}$ للقيمة x الواقعة على المحور الأفقي OX التي يقع على يسارها وتحت منحنى دالة الكثافة الاحتمالية $f(x; m, n)$ مساحة قدرها α (قيمة هذه المساحة تساوي $P(X < x)$)، فعلى سبيل المثال من أجل $m=10$ و $n=5$ و $\alpha=0.90$ يكون لدينا $f_{0.90}^{[10, 5]} = 3.30$ أي إنه لدينا من أجل هذا التوزيع $P(X < 3.30) = 0.90$ (للتوضيح انظر (٦، ٣١) ب. الآتي).
- ٤- باستخدام تعريف دالة التوزيع الاحتمالية لمتغير عشوائي مستمر يكون لدالة توزيع هذا المتغير العشوائي العرض الآتي :

$$F_X(x) = \int_{-\infty}^x \frac{\left(\frac{m}{n}\right)^{\frac{m}{2}}}{\beta\left(\frac{m}{2}, \frac{n}{2}\right)} t^{\frac{m}{2}-1} \left(1 + \frac{mt}{n}\right)^{-\frac{m+n}{2}} \mathbf{I}_{(0,\infty)}(t) dt \quad ; \forall x \in \mathbb{R}$$

ومن أجل $m = 10$ و $n = 5$ يكون لرسمها البياني الشكل الآتي (٦, ٣١ ج)، وأما لحساب قيم دالة التوزيع الاحتمالية السابقة فإنه يوجد جدول في آخر هذا الكتاب يعطينا قيماً لهذه الدالة من أجل قيم مختلفة لـ m و n ، فعلى سبيل المثال: من أجل $m = 8$ و $n = 10$ مع $\alpha = 0.99$ يكون لدينا $f_{0.99}^{[8,10]} = 5.06$ ، أي إن $P(X < 5.06) = 0.99$.



الشكل (٦, ٣١ ج) دالة التوزيع الاحتمالية لتوزيع فيشر



الشكل (٦, ٣١ ب) المساحة الواقعة على يسار النقطة $x = 3.30$

تطبيقات على هذا التوزيع نجدها لاحقاً في مجال الإحصاء الرياضي.

(٦, ٣) تقارب بعض التوزيعات الاحتمالية من بعضها الآخر

Convergence of some probability distributions to others

لقد لاحظنا في صيغة الحساب الاحتمالي لمتغير عشوائي خاضع للتوزيع فوق الهندسي أنه من الصعوبة حساب قيمة الاحتمال عندما تصبح قيم المعلمتين M و N كبيرة، ولذلك سنقدم فيما يلي بعض المبرهنات (سيترك براهينها كتمارين للقارئ لأنها ذات طابع رياضي) التي تبين لنا تقارب بعض التوزيعات الاحتمالية من بعضها الآخر لدى تحقق شروط محددة، ومن ثم يمكننا استخدام توزيع احتمالي عوضاً عن آخر عند تحقق هذه الشروط أو على الأقل تحقق قيم تسمح لنا باستخدام هذا التقريب؛ وذلك لتجنب الصعوبات في العمليات الحسابية التي قد تواجهنا لدى التوزيع الأصل.

(٦, ٣, ١) مبرهنة (بخصوص تقارب التوزيع فوق الهندسي من الحداني)

لتكن M, N و n من \mathbb{N} مع $N > M$ و $N \geq n$ ، فعندئذ من أجل كل $N^0 \ni k$ مع:

$$\max\{0, n + M - N\} \leq k \leq \min\{n, M\}$$

ستكون العلاقة الآتية محققة:

$$\lim_{\substack{N \rightarrow \infty \\ M \rightarrow \infty \\ \frac{M}{N} \rightarrow p}} \binom{M}{k} \cdot \binom{N-M}{n-k} \cdot \binom{N}{n}^{-1} = \binom{n}{k} p^k (1-p)^{n-k} \quad [6,17]$$

(٦, ٣, ٢, ١) نتيجة

من المبرهنة السابقة (٦, ٣, ١) نستنتج أنه يمكننا استخدام التوزيع الحداني لحساب احتمالات تتعلق بمتغير عشوائي X خاضع للتوزيع فوق الهندسي، وذلك عندما تكون M و N كبيرة بقدر كاف على أن نأخذ $p = \frac{M}{N}$. إن عملية الحساب هذه سيتبع عنها خطأ صغير في قيمة الاحتمال، ولكن هذا الخطأ يمكن إهماله عندما يكون الاحتمال المطلوب صعب الحساب وفقاً للتوزيع الأصل.

(٦, ٣, ٢, ٢) ملاحظات

١- في الجوانب التطبيقية ينصبّ الاهتمام على كبر قيمة N بشكل أساسي، وأن تكون $n \ll N$ (أي N أكبر بكثير من n). علماً أنّ مسألة الحكم على القيمة N بأنها كبيرة بقدر كافٍ بالنسبة إلى n تعود إلى إمكانيات المرء وليس هناك معيار مُحدد لتبيان قيمة N إن كانت كبيرة بقدر كافٍ بالنسبة إلى n أم لا، ولكن في الجوانب الإحصائية ينظر إلى أنّ N كبيرة بقدر كافٍ بالنسبة إلى n إذا كان $0.05 N \geq n$ التي نجد منها أنّ $20 n \leq N$.

٢- إضافة لما سبق فإننا سنصطلح (وعلى سبيل التبسيط) أنّه إذا كانت قيمة عددية صحيحة $100 \leq x$ (عادةً تأخذ $1000 \leq x$) فإننا سنتعامل معها على أنّها كبيرة بقدر كافٍ (وُرمز لذلك بـ $x \gg 1$)، وكذلك إذا كانت قيمة عددية حقيقية $0.01 \geq x$ (عادةً تأخذ $1000 \geq x$) فإننا سنتعامل معها على أنّها صغيرة بقدر كافٍ (وُرمز لذلك بـ $x \ll 1$).

لقد لاحظنا أنّ المبرهنة السابقة تسمح لنا باستخدام التوزيع الحداني عوضاً عن التوزيع فوق الهندسي من أجل شروط محدّدة، ولكن عندما تصبح قيمة n كبيرة بقدر كافٍ و p صغيرة بقدر كافٍ أيضاً فإنّ حساب الاحتمال المطلوب باستخدام التوزيع الحداني يصبح صعباً في كثير من الحالات، ولذلك قدّم تقريّب آخر للتوزيع الحداني بحيث يصبح معه حساب الاحتمال المطلوب أكثر يسراً وسهولة. إنّ المبرهنة الآتية تسمح لنا باستخدام توزيع بواسوني عوضاً عن التوزيع الحداني عندما تكون n كبيرة بقدر كافٍ و p صغيرة بقدر كافٍ.

(٦, ٣, ٢) مبرهنة (بخصوص تقارب التوزيع الحداني من البواسوني)

ليكن $N \ni k$ و $0 < p < 1$ ، فعندئذ من أجل كل $N^0 \ni k$ تكون العلاقة الآتية مُحَقَّقة:

$$\lim_{\substack{n \rightarrow \infty \\ p \rightarrow 0 \\ n \cdot p \rightarrow \lambda}} \binom{n}{k} p^k (1-p)^{n-k} = \frac{\lambda^k}{k!} e^{-\lambda} \quad [6,18]$$

(٦, ٣, ٢, ١) نتيجة

نستنتج من المبرهنة السابقة (٦, ٣, ٢) أنّه عندما تكون $n \ll 1$ وكذلك $p \gg 1$ ، فإنّه يمكننا استخدام توزيع بواسون لحساب احتمالات تتعلّق بمتغيّر عشوائي X خاضع للتوزيع الحداني على أن نأخذ قيمة الوسيط $\lambda = n \cdot p$ ، وفي هذه الحالة ينشأ لدينا خطأ صغير يمكن إهماله بسبب صعوبة حساب هذا الاحتمال باستخدام التوزيع الأصل.

تواجهنا في الواقع صعوبات في حساب احتمال يتعلّق بالتوزيع الحداني عندما تكون $n \ll 1$ وكذلك $p \gg 1$ ، وهي ذات الصعوبات التي تواجهنا في حساب احتمال يتعلّق بالتوزيع الحداني السالب عندما تكون $n \ll 1$ و p قريبة جداً من الواحد، ولهذا السبب قدّم تقريّب لحساب احتمال يتعلّق بالتوزيع الحداني السالب باستخدام التوزيع البواسوني أيضاً، وهذا ما تبينه لنا المبرهنة الآتية.

(٦, ٣, ٣) مبرهنة (بخصوص تقارب التوزيع الحداني السالب من البواسوني)

من أجل كل $N \ni n$ ، $N^0 \ni k$ و $0 < p < 1$ يكون لدينا ما يلي مُحَقَّقاً:

$$\lim_{\substack{n \rightarrow \infty \\ p \rightarrow 1 \\ \frac{n(1-p)}{p} \rightarrow \lambda}} \binom{k+n-1}{k} p^n (1-p)^k = \frac{\lambda^k}{k!} e^{-\lambda} \quad [6,19]$$

(٦, ٣, ٣, ١) نتيجة

من هذه المبرهنة نستنتج أنّه يمكننا استخدام التوزيع البواسوني عوضاً عن الحداني السالب في حساب الاحتمال المطلوب على

أن نأخذ $\lambda := \frac{n(1-p)}{p}$ ، وبعد الأخذ بالحسبان أن n كبيرة بقدر كافٍ و p قريبة من الواحد بقدر كافٍ.

(٢, ٣, ٣, ٦) أمثلة

١- يوجد في جامعة 10000 طالب منهم 10 طلاب متميزين على مستوى جامعات البلد، فعندئذ:

أ- إذا كنا سنخضع كل طالب وبشكل مستقل عن الآخر لاختبار التميز، فما هو احتمال أن يكون لدينا طالبين متميزين من بين الطلاب المختبرين في الحالتين الآتيتين:

أ-١- إذا تم سحب عشوائي ل 50 طالباً من طلاب هذه الجامعة؟

أ-٢- إذا تم سحب عشوائي ل 500 طالب من طلاب هذه الجامعة؟

ب- إذا كنا سنخضع كل طالب للاختبار، وأتينا سنكتفي بالعدد الذي يوافق حصولنا على أول طالب متميز، فعندئذ:

ب-١- ما هو احتمال أن نجري خمسة اختبارات فقط؟

ب-٢- ما هو احتمال أن نجري مئة اختبار للحصول على هذا الطالب المتميز؟

ج- سُجبت عينة عشوائية (دفعلة واحدة) بحجم 500 طالب، فما هو احتمال أن تحوي هذه العينة على جميع الطلاب المتميزين؟

د- إذا كنا سنخضع كل طالب وبشكل مستقل عن الآخر لاختبار التميز، وأتينا سنتابع في تنفيذ الاختبارات على الطلاب حتى الحصول على ثلاثة طلاب متميزين فتتوقف عن الاختبارات، فما هو احتمال أن نقوم بتنفيذ تسعة اختبارات؟

الحل: من أجل الطلب:

أ- لנأخذ X متغيراً عشوائياً راصداً لعدد الطلاب المتميزين الذين سنحصل عليهم نتيجة للاختبارات التي سنجرها، فعندئذ سيكون هذا المتغير العشوائي خاضعاً للتوزيع الحداني، أي إن الاحتمال المطلوب يحسب بالعلاقة الآتية:

$$P(X = k) = \binom{n}{k} p^k (1-p)^{n-k} \quad k = 0, 1, 2, \dots, n$$

ومن ثم يكون لدينا من أجل الطلب:

أ-١- لدينا معاً هذا التوزيع هي $n = 50$ و $p = \frac{10}{10000} = 0.001$ ، والاحتمال المطلوب هو $P(X = 2)$ ، فيكون لدينا:

$$P(X = 2) = \binom{50}{2} 0.001^2 (1-0.001)^{48} = 1225 \times 10^{-6} \times 0.953 = 0.00117$$

أ-٢- لدينا معاً هذا التوزيع هي $n = 500$ و $p = \frac{10}{10000} = 0.001$ ، والاحتمال المطلوب هو $P(X = 2)$ ، حيث نجد:

$$P(X = 2) = \binom{500}{2} 0.001^2 (1-0.001)^{498} = 124750 \times 10^{-6} \times 0.6076 = 0.0757981$$

ونلاحظ هنا أنه يمكننا استخدام توزيع بواسون بدلاً عن التوزيع الحداني على أن نأخذ قيمة المعلمة λ كما يلي:

$$\lambda = n \cdot p = 500 \times 0.001 = 0.5$$

فيكون لدينا:

$$P(X = 2) = \frac{0.5^2}{2!} e^{-0.5} = 0.075816$$

فيلاحظ أن القيمتين قريبتين جداً من بعضهما، ولكن حساب المقدار الأخير أكثر سهولة.

ب- ليكن X متغيراً عشوائياً راصداً لعدد الاختبارات التي سنجرها حتى حصولنا على أول طالب متميز، فعندئذ سيخضع

هذا المتغير العشوائي إلى التوزيع الهندسي، أي إن الاحتمال المطلوب يحسب بالعلاقة الآتية:

$$P(X = k) = (1-p)^{k-1} \cdot p$$

حيث لدينا $p = 0.001$ ، ومن ثم يكون من أجل الطلب:

ب-١- الاحتمال المطلوب هو:

$$P(X = 5) = (0.999)^4 \cdot 0.001 = 0.000996$$

ب-٢- الاحتمال المطلوب هو:

$$P(X = 100) = (0.999)^{99} \cdot 0.001 = 0.0009057$$

وهذا يعني أن احتمال حصولنا على طالب متميز باختبارات سابقة سيكون أكبر.

ج- لنأخذ X متغيراً عشوائياً راصداً لعدد الطلاب المتميزين في العينة المسحوبة، فعندئذ سيكون لهذا المتغير العشوائي توزيع فوق هندسي، أي إن الاحتمال المطلوب يحسب بالعلاقة الآتية:

$$P(X = k) = \binom{M}{k} \cdot \binom{N-M}{n-k} \cdot \binom{N}{n}^{-1}$$

ومن أجل مسألتنا هذه لدينا $N = 10000$ ، $M = 10$ و $n = 500$ ، ومن ثم الاحتمال المطلوب هو:

$$P(X = 10) = \binom{500}{10} \cdot \binom{4500}{190} \cdot \binom{10000}{500}^{-1}$$

وبملاحظة صعوبة حساب المقدار الأخير فإننا سنستخدم التوزيع الحداني في حساب الاحتمال المطلوب عوضاً عن التوزيع فوق الهندسي، أي سنستخدم العلاقة الآتية لحساب الاحتمال المطلوب:

$$P(X = k) = \binom{n}{k} p^k (1-p)^{n-k}$$

على أن نأخذ قيم العالم $n = 500$ و $p = \frac{M}{N} = 0.001$ ، ومن ثم يكون الاحتمال المطلوب هو:

$$P(X = 10) = \binom{500}{10} 0.01^{10} (0.999)^{990}$$

ويمكننا هنا أن نتابع بتقريب التوزيع السابق إلى توزيع بواسوني أيضاً، ومن ثم نستخدم العلاقة الآتية لحساب الاحتمال المطلوب:

$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}$$

على أن نأخذ قيمة المعلمة $\lambda = n \cdot p = 500 \times 0.001 = 0.5$ ، ولذلك يكون لدينا:

$$P(X = 10) = \frac{0.5^{10}}{10!} e^{-0.5} = 1.63226 \times 10^{-10}$$

د- ليكن X متغيراً عشوائياً راصداً لعدد الاختبارات المنفذة التي نفشل فيها حتى الحصول على ثلاثة طلاب متميزين، فعندئذ سيكون لهذا المتغير العشوائي توزيع حداني سالب بمعلمتين $n = 3$ و $p = 0.001$ ، ومن ثم سنستخدم العلاقة $[6,5-a]$ لحساب الاحتمال المطلوب، حيث لدينا:

$$P(X = k) = \binom{k+n-1}{k} \cdot p^n \cdot (1-p)^k$$

ومنه يكون الاحتمال المطلوب هو:

$$P(X = 6) = \tilde{b}(6; 3, 0.001) = \binom{6+3-1}{6} (0.001)^3 (0.999)^6 = 2.7832 \times 10^{-8}$$

بالطبع كان من الممكن أن نوجد الحل بالطريقة الآتية أيضاً.

ليكن X متغيراً عشوائياً راصداً لعدد الاختبارات المنفّذة حتى الحصول على ثلاثة طلاب متميزين، فعندئذ سيكون لهذا المتغير العشوائي توزيع حداني سالب بمعلمتين $n = 3$ و $p = 0.001$ حيث لدينا العلاقة [6,5-c]:

$$P(X = k) = \binom{k-1}{n-1} p^n (1-p)^{k-n}$$

التي نجد منها ذات النتيجة التي حصلنا عليها سابقاً، حيث لدينا:

$$P(X = 9) = \binom{9-1}{2} (0.001)^3 (0.999)^6 = 2.7832 \times 10^{-8}$$

هذا ما تيسّر تقديمه من أجل الجزء النظري والتطبيقي لهذا الفصل

تمارين الفصل السادس

١- بين أي من الدوال الآتية تصلح لأن تكون دالة كثافة احتمالية لمتغير عشوائي:

$$\begin{array}{ll} \text{a) } f(x) = \begin{cases} \frac{8}{3}x^2 & \text{for } x \in [-0.5, 1] \\ 0 & \text{otherwise} \end{cases} & \& \text{b) } f(x) = \begin{cases} \frac{1}{3}x & \text{for } x \in (-1, 5) \\ 0 & \text{otherwise} \end{cases} \\ \text{c) } f(x) = \begin{cases} \frac{1}{8} & \text{for } x \in [1, 4) \\ 0 & \text{otherwise} \end{cases} & \& \text{a) } f(x) = \begin{cases} \frac{3}{26}x^2 & \text{for } x \in [1, 3] \\ 0 & \text{otherwise} \end{cases} \end{array}$$

٢- بين أي من الدوال الآتية تصلح لأن تكون دالة توزيع احتمالية لمتغير عشوائي:

$$\begin{array}{ll} \text{a) } F(x) = \begin{cases} \frac{1}{2} & \text{for } x \leq -1 \\ 2x & \text{for } -1 < x \leq +1 \\ 1 & \text{otherwise} \end{cases} & \& \text{b) } F(x) = \begin{cases} 0 & \text{for } x \leq 5 \\ x^3 & \text{for } 5 < x \leq 10 \\ 0.95 & \text{otherwise} \end{cases} \\ \text{b) } F(x) = \begin{cases} 0 & \text{for } x \leq -5 \\ e^x & \text{for } -5 < x \leq 0 \\ 1 & \text{otherwise} \end{cases} & \& \text{c) } F(x) = \begin{cases} e^x & \text{for } x \leq 0 \\ x + 0.5 & \text{for } 0 < x \leq 0.5 \\ 1 & \text{otherwise} \end{cases} \end{array}$$

٣- بين أي مما يلي تصلح لأن تكون دالة كتلة احتمالية لمتغير عشوائي:

$$\begin{array}{ll} \text{a) } P(X = x) = \frac{x}{6} ; x \in \mathbb{N}_6 & \& \text{b) } P(X = k) = \frac{1}{100} ; k \in \mathbb{N}_{100} \\ \text{c) } P(X = x) = \frac{2^k}{k!} e^{-2} ; k = 0, 1, 2 & \& \text{c) } P(X = x) = \frac{1}{4} - x ; x = \frac{1}{2}, \frac{1}{4}, \frac{1}{6}, \frac{1}{8} \end{array}$$

٤- بين أي مما يلي تصلح لأن تكون دالة توزيع احتمالية لمتغير عشوائي متقطع:

$$\begin{array}{ll} \text{a) } F(x) = \begin{cases} \frac{1}{2} & \text{for } x \leq 0 \\ 0.5 & \text{for } 0 < x \leq 4 \\ 1 & \text{otherwise} \end{cases} & \& \text{b) } F(x) = \begin{cases} e^x & \text{for } x \leq 0 \\ 1 & \text{otherwise} \end{cases} \\ \text{b) } F(x) = \begin{cases} 0 & \text{for } x \leq -2 \\ 0.75 & \text{for } -2 < x \leq 10 \\ 1 & \text{otherwise} \end{cases} & \& \text{c) } F(x) = \begin{cases} 0 & \text{for } x \leq 70 \\ 0.25 & \text{for } 70 < x \leq 105 \\ 0.99 & \text{otherwise} \end{cases} \end{array}$$

٥- يوجد في مدينة 4000000 سيارة منها 4000 سيارة لم تقم بتجديد رخصة السير، فقامت دورية شرطة المرور بإنشاء حاجز على طريق ما في هذه المدينة للتحقق من صلاحية رخصة السير. عندئذ:

أ- إذا تم استجواب 500 سائق سيارة على هذا الطريق، فما هو احتمال أن يكون قد تم ضبط 10 سيارات تسير برخصة سير منتهية الصلاحية؟

ب- إذا كان الاستجواب سوف يستمر حتى يتم ضبط أول سيارة تسير برخصة سير منتهية الصلاحية فتوقفها وتذهب بها إلى

- الحجز وتنتهي عملية التفتيش، فما هو احتمال أن يكون قد تم استجواب سائقي 50 سيارة؟
- ج- إذا كان الاستجواب سوف يستمر حتى يتم ضبط 10 سيارات تسير برخصة سير منتهية الصلاحية فتأخذ هذه السيارات إلى الحجز وتنتهي عملية التفتيش، فما هو احتمال أن يكون قد تم استجواب سائقي 100 سيارة حتى إنهاء عملية التفتيش؟
- د- إذا قامت الدورية بعملية تفتيش لجميع السيارات الموجودة في حي معين والحاوي على 5000 سيارة، فما هو احتمال أن يكون قد تم ضبط 30 سيارة برخصة سير منتهية الصلاحية؟
- ٦- يقوم رجل بالرمي على هدف، فإذا علمنا أن احتمال إصابة الهدف من قبل الرجل يساوي 0.85، وأن الرجل بعد كل رمية تؤخذ منه البندقة ويعطى بندقية أخرى مختلفة عن سابقتها، وكذلك لا يمكنه معرفة نتيجة رميته على الهدف (أي الرميات على الهدف يتم بشكل مستقل كل منها عن الآخر)، فعندئذ:
- أ- كم رمية يجب على الرامي أن يطلقها على الهدف حتى يصبح احتمال إصابة الهدف أكبر من 0.9999؟
- ب- بفرض أن الرجل أطلق 12 رمية على الهدف فما هو احتمال أن يصيب بسبع منها؟
- ج- بفرض أنه سيطلب من الرجل التوقف عن الرمي (دون علمه بذلك مسبقاً) لدى تحقيقه إصابة للهدف، فما هو احتمال أن يكون قد أطلق الرجل خمس رميات على الهدف فقط؟
- د - بفرض أنه سيطلب من الرجل التوقف عن الرمي (دون علمه بذلك مسبقاً) لدى تحقيقه ثلاث إصابات للهدف، فما هو احتمال أن يكون قد أطلق الرجل سبع رميات على الهدف فقط؟
- ٧- ليكن X متغيراً عشوائياً قانون توزيعه مُعطى من خلال الجدول الآتي:

i	1	2	3	4	sum
x_i قيم X	0	1	2	3	
$p_i = P(X = x_i)$	$\frac{16}{64}$	$\frac{16}{64}$	$\frac{16}{64}$	$\frac{16}{64}$	1

والمطلوب تعيين نوع هذا المتغير العشوائي، ومن ثم حساب الاحتمالات الآتية:

- a) $P(X \geq 1) = ?$ b) $P(0.5 \leq X < 2.5) = ?$ c) $P(X \leq 1.25) = ?$

٨- ليكن X متغيراً عشوائياً قانون توزيعه مُعطى من خلال الجدول الآتي:

i	1	2	3	4	5	6	sum
x_i قيم X	1	2	3	4	5	6	
$p_i = P(X = x_i)$	0.04	0.20	0.30	0.40	?	0.05	

علماً أن ؟ تشير إلى أن قيمة الاحتمال مجهولة، والمطلوب ما يلي:

أ- تعيين قيمة الاحتمال المجهولة.

ب- تعيين نوع هذا المتغير العشوائي، ومن ثم حساب الاحتمالات الآتية:

- a) $P(X < 4) = ?$ b) $P(X < 0.5) = ?$ c) $P(X > 1.25) = ?$

٩- في نظام الاتحاد الرياضي لبلد ما أن الفريق الذي يفوز ب 10 مباريات من أصل 12 مباراة يمكنه الانتقال من أندية الدرجة الثانية إلى أندية الدرجة الأولى. فلو افترضنا أن كل مباراة تجري بشكل مستقل عن الأخرى، فعندئذ:

أ- إذا كان احتمال فوز فريق A في أية مباراة يساوي 0.65 وأنه قد فاز بأربع مباريات من أصل ست مباريات، فما هو احتمال أن يحقق الفريق A الانتقال إلى أندية الدرجة الأولى؟

ب- إذا كان احتمال فوز فريق A في أية مباراة يساوي 0.65 وأنه قد فاز بأربع مباريات من أصل ست مباريات، وهناك فريق آخر B احتمال فوزه في أية مباراة يساوي 0.60 وأنه قد فاز بست مباريات من أصل ثمان مباريات، فأى الفريقين له احتمال أكبر في الانتقال إلى أندية الدرجة الأولى؟

١٠- إذا علمت أن احتمال أن تنجح عملية جراحية من نوع معين لمريض هو 0.85، وأن العمليات تُجرى بشكل مستقل كل منها عن الأخرى، فعندئذ:

أ- ما هو احتمال نجاح العملية لخمسة مرضى من أصل 7 مرضى ستجرى لهم هذه العملية؟

ب- إذا كان طاقم العمل الجراحي سيستمر في إجراء هذا النوع من العمليات الجراحية على المرضى حتى حدوث أول فشل لهذه العملية حيث يتوقف الطاقم عن تنفيذ هذا النوع من العمليات، فما هو احتمال أن يقوم هذا الطاقم بتنفيذ 15 عملية جراحية؟

ج- إذا كان طاقم العمل الجراحي سيستمر في إجراء هذا النوع من العمليات الجراحية على المرضى حتى يتبين لهم فشلها للمرة الثالثة حيث يتوقف الطاقم عن تنفيذ هذا النوع من العمليات الجراحية، فما هو احتمال أن يقوم هذا الطاقم بتنفيذ 30 عملية جراحية قبل توقفه عن تنفيذ هذا النوع من العمليات؟

١١- لدى شركة طيران مدنية نوعين من الطائرات تعمل بالنوع نفسه من المحركات، ولكن النوع الأول يعمل بأربع محركات، وأما النوع الثاني فيعمل بمحركين فقط. لو افترضنا أن محركات الطائرات تعمل بشكل مستقل كل منها عن الأخرى وفي كل من النوعين، وأن احتمال تعطل محرك عن العمل أثناء الطيران يساوي 0.001، وأن الطائرة يمكن لها أن تتم رحلتها إذا كان نصف عدد محركاتها على الأقل في حالة العمل. عندئذ بين أي النوعين من الطائرات أكثر أماناً للوصول إلى هدفها.

١٢- في إحدى الكليات يوجد 120 محاضراً (من مختلف المراتب العلمية) و 30 قائماً بالأعمال. أرادت عمادة الكلية تشكيل لجنة استشارية مكونة من 15 شخصاً يسحبون عشوائياً من الكادر العامل في هذه الكلية، فما هو احتمال أن يكون في هذه اللجنة خمسة محاضرين على الأقل؟

١٣- يشير استطلاع للرأي حول التدخين أنه من كل 1000 شخص يوجد بينهم 50 شخصاً مدخناً، فلو قمنا بسؤال 250 شخصاً اختيروا بشكل عشوائي، فما هو احتمال أن يكون من بينهم تسعة أشخاص مدخين على الأكثر؟

١٤- ليكن X متغيراً عشوائياً خاضعاً للتوزيع الطبيعي بمعلمتين $\mu = 5$ و $\sigma = 1.5$ ، والمطلوب حساب الاحتمالات الآتية:

$$a) P(X \leq 7) = ? \quad b) P(3 \leq X \leq 7) = ? \quad c) P(X > 8) = ? \quad d) P(-5 < X < -2) = ?$$

١٥- في مصنع لإنتاج المكاس الكهربائية يوجد أربعة خطوط للإنتاج L_1 ، L_2 ، L_3 و L_4 لها القدرة نفسها في الإنتاج، ولكن نسبة المعيب في إنتاج هذه الخطوط هو 0.01، 0.02، 0.03 و 0.04 على الترتيب. عندئذ أجب عما يلي:

أ- نقوم بسحب عشوائي لمكنسة من الإنتاج الكلي للمصنع، فما هو احتمال أن تكون المحوطة المسحوبة صالحة للاستخدام؟

ب- قمنا بسحب عشرة مكاس واحدة تلو الأخرى من الإنتاج الكلي للمصنع ومن ثم فحصها، فما هو احتمال حصولنا على مكنستين معيبتين فقط؟

ج- بفرض أن المصنع أنتج 1000 مكنسة وقمنا ببيع 200 مكنسة سحبت عشوائياً من هذا الإنتاج، فما هو احتمال أن تكون جميع المكناس التي تم بيعها ليست معيبة؟

د- بفرض أن عمر أي مكنسة (مقدرة بالسنة) يخضع للتوزيع الأسّي بمتوسط ثلاث سنوات، فعندئذ:

١- عين قيمة المعلمة لتوزيع (للتوزيع الأسّي) أعمار المكناس؟

٢- أحسب احتمال ألا تُعمر مكنسة من إنتاج هذا المصنع أكثر من خمس سنوات؟

٣- إذا عملت هذه المكنسة لثلاث سنوات فما هو احتمال أن تعمل لثلاث سنوات قادمة أيضاً؟

١٦- لناخذ تجربة إلقاء حجر نرد متوازن لمرتين متتاليتين، وليكن X متغيراً عشوائياً فوق الفضاء الاحتمالي لهذه التجربة معرفاً كما يلي:

$$X(\omega) := \begin{cases} -1 & \text{if } \omega \text{ is an odd number} \\ +1 & \text{if } \omega \text{ is an even number} \end{cases}$$

عندئذ المطلوب ما يلي:

أ- لأي توزيع يخضع هذا المتغير العشوائي، ولماذا؟

ب- عين دالة توزيع هذا المتغير العشوائي، ومن ثم ارسمها.

ج- أستخدم دالة التوزيع لحساب الاحتمالات الآتية:

a) $P(X \geq -0.5) = ?$

b) $P(-1 < X \leq 0.5) = ?$

c) $P(X < 0.8) = ?$

الفصل السابع

استقلال وعزوم المتغيرات العشوائية

INDEPENDENCE AND MOMENTS OF RANDOM VARIABLES

(٧, ١) استقلال المتغيرات العشوائية

Independence of Random Variables

لقد قدمنا في الفصل الرابع دراسة الاستقلال للحوادث، وفيما يلي سنقدم دراسة مبسطة وموجزة حول استقلال المتغيرات العشوائية.

(٧, ١, ١) الاستقلال لعدد منته من المتغيرات العشوائية

نقدم في هذه الفقرة مفهوم الاستقلال لعدد منته من المتغيرات العشوائية مع بعض الاختبارات التي تساعدنا في اتخاذ قرار بشأن ذلك.

(٧, ١, ١, ١) تعريف (الاستقلال لعدد منته من المتغيرات العشوائية)

لتكن X_1, X_2, \dots, X_n متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، علماً أن $2 \leq n$ عدد صحيح، فعندئذ يُقال عن هذه المتغيرات العشوائية إنها **مستقلة عشوائياً** (أو **مستقلة إحصائياً**) إذا كان من أجل أية حوادث (مجموعات بوريلية) A_1, A_2, \dots, A_n من \mathcal{R} لدينا العلاقة الآتية مُحَقَّقة:

$$P(X_1 \in A_1, X_2 \in A_2, \dots, X_n \in A_n) = \prod_{k=1}^n P(X_k \in A_k) \quad [7,1]$$

علماً أن Π يرمز إلى الضرب (المعروف) بين المقادير العددية.

(٧, ١, ١, ٢) ملاحظات

١- حيثما ترد عبارة متغيرات عشوائية **مستقلة** إنما يقصد بها متغيرات عشوائية **مستقلة عشوائياً**.

٢- في الحالة الخاصة، إذا كان من أجل كل i و j من N_n مع $i \neq j$ لدينا:

$$P(X_i \in A_i, X_j \in A_j) = P(X_i \in A_i) \cdot P(X_j \in A_j) \quad [7,2]$$

فعندئذ يُقال عن المتغيرات العشوائية X_1, X_2, \dots, X_n إنها **مستقلة مثني مثني**.

(٧, ١, ١, ٣) مثال

ليكن X, Y, Z متغيرات عشوائية فوق الفضاء الاحتمالي لتجربة إلقاء قطعة نقود متوازنة لمرتين متتاليتين، ومعرفة من أجل كل $\omega \in \Omega$ كما يلي:

$$X(\omega) = \mathbf{I}_{\{HH, HT\}}(\omega) \quad \& \quad Y(\omega) = \mathbf{I}_{\{HH, TH\}}(\omega) \quad \& \quad Z(\omega) = \mathbf{I}_{\{HH, TT\}}(\omega)$$

فنجدها أن:

$$P(X=1) = P(X=0) = P(Y=1) = P(Y=0) = P(Z=1) = P(Z=0) = \frac{1}{4}$$

$$P(X=1, Y=1) = P(X=0, Y=1) = P(X=1, Y=0) = P(X=0, Y=0) = \frac{1}{4}$$

$$P(X=1, Z=1) = P(X=0, Z=1) = P(X=1, Z=0) = P(X=0, Z=0) = \frac{1}{4}$$

$$P(Y=1, Z=1) = P(Y=0, Z=1) = P(Y=1, Z=0) = P(Y=0, Z=0) = \frac{1}{4}$$

ومن هذه العلاقات ينتج لدينا أن المتغيرات العشوائية X, Y, Z مستقلة متشعبة، ولكنها ليست مستقلة وذلك لأن:

$$P(X=1, Y=1, Z=1) = P(\{HH\}) = \frac{1}{4} \quad \& \quad P(X=1) \cdot P(Y=1) \cdot P(Z=1) = \frac{1}{8}$$

ومن ثم يكون:

$$P(X=1, Y=1, Z=1) \neq P(X=1) \cdot P(Y=1) \cdot P(Z=1)$$

(٤، ١، ١، ٧) ملاحظة

يوضح لنا المثال السابق أنه إذا كانت X_1, X_2, \dots, X_n مستقلة متشعبة فليس بالضرورة أن تكون هذه المتغيرات العشوائية مستقلة، ولكن العكس صحيح، وهذا ما ستبينه لنا المبرهنة الآتية.

(٥، ١، ١، ٧) مبرهنة

لتكن X_1, X_2, \dots, X_n متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فإذا كانت هذه المتغيرات العشوائية مستقلة، فعندئذ ستكون أية أسرة جزئية منها مستقلة أيضاً.

البرهان: لنأخذ $X_{\alpha_1}, X_{\alpha_2}, \dots, X_{\alpha_s}$ أسرة جزئية من المتغيرات العشوائية المعطاة، علماً أن $1 < s \leq n$ وكذلك $\alpha_1 \leq n$ ، $\alpha_2, \dots, \alpha_s$ أعداد صحيحة مختلف بعضها عن بعض، ولنرمز لبقية المتغيرات العشوائية بـ $X_{\beta_1}, X_{\beta_2}, \dots, X_{\beta_r}$ مع $\beta_1 \leq n$ ، β_2, \dots, β_r أعداد صحيحة مختلف بعضها عن بعض، وكذلك مختلفة عن القيم $\alpha_1, \alpha_2, \dots, \alpha_s$ ، علماً أن $r = n - s$ ، فعندئذ بأخذ B_1, B_2, \dots, B_s من \mathcal{R} ، فإنه بسبب استقلال X_1, X_2, \dots, X_n يمكننا أن نكتب الآتي:

$$\begin{aligned} P(X_{\alpha_1} \in B_1, X_{\alpha_2} \in B_2, \dots, X_{\alpha_s} \in B_s) &= P\left(X_{\alpha_1} \in B_1, X_{\alpha_2} \in B_2, \dots, X_{\alpha_s} \in B_s, \right. \\ &\quad \left. X_{\beta_1} \in \mathbb{R}, X_{\beta_2} \in \mathbb{R}, \dots, X_{\beta_r} \in \mathbb{R}\right) \\ &= P(X_{\alpha_1} \in B_1) \cdot P(X_{\alpha_2} \in B_2) \cdot \dots \cdot P(X_{\alpha_s} \in B_s) \cdot \underbrace{P(X_{\beta_1} \in \mathbb{R})}_{=1} \cdot \underbrace{P(X_{\beta_2} \in \mathbb{R})}_{=1} \cdot \dots \cdot \underbrace{P(X_{\beta_r} \in \mathbb{R})}_{=1} \\ &= P(X_{\alpha_1} \in B_1) \cdot P(X_{\alpha_2} \in B_2) \cdot \dots \cdot P(X_{\alpha_s} \in B_s) \end{aligned}$$

وهذا يعني أن المتغيرات العشوائية $X_{\alpha_1}, X_{\alpha_2}, \dots, X_{\alpha_s}$ مستقلة، وبهذا يتم البرهان.

المبرهنة الآتية تعرض لنا إحدى الخصائص المهمة المتعلقة باستقلال المتغيرات العشوائية.

(٦, ١, ١, ٧) مبرهنة

لتكن X_1, X_2, \dots, X_n متغيرات عشوائية مستقلة فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، ولتكن g_1, g_2, \dots, g_n دوال حقيقية معرفة على \mathbb{R} وقيوسة بالنسبة إلى \mathcal{R} أيضاً، فعندئذ تكون المتغيرات العشوائية $g_1(X_1), g_2(X_2), \dots, g_n(X_n)$ مستقلة أيضاً.

البرهان: لنأخذ B_1, B_2, \dots, B_n من \mathcal{R} ، فعندئذ يمكننا أن نكتب الآتي:

$$P(g_1(X_1) \in B_1, g_2(X_2) \in B_2, \dots, g_n(X_n) \in B_n) = P(X_1 \in g_1^{-1}(B_1), X_2 \in g_2^{-1}(B_2), \dots, X_n \in g_n^{-1}(B_n))$$

ومن كون الدوال g_k قيوسة بالنسبة إلى \mathcal{R} من أجل كل $k \in \mathbb{N}_n$ ، فإنه سيكون لدينا:

$$g_k^{-1}(B_k) \in \mathcal{R} \quad ; \forall k \in \mathbb{N}_n$$

وبما أن X_1, X_2, \dots, X_n مستقلة، فإنه سيتبع لدينا ما يلي:

$$\begin{aligned} P(X_1 \in g_1^{-1}(B_1), X_2 \in g_2^{-1}(B_2), \dots, X_n \in g_n^{-1}(B_n)) \\ = P(X_1 \in g_1^{-1}(B_1)) \cdot P(X_2 \in g_2^{-1}(B_2)) \cdot \dots \cdot P(X_n \in g_n^{-1}(B_n)) \\ = P(g_1(X_1) \in B_1) \cdot P(g_2(X_2) \in B_2) \cdot \dots \cdot P(g_n(X_n) \in B_n) \end{aligned}$$

وهذا يعني أن المتغيرات العشوائية $g_1(X_1), g_2(X_2), \dots, g_n(X_n)$ مستقلة، وبهذا يتم البرهان.

(٧, ١, ١, ٧) أمثلة

١- لتكن X_1, X_2, \dots, X_n متغيرات عشوائية مستقلة فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، ولنأخذ g_1, g_2, \dots, g_n دوال حقيقية معرفة على \mathbb{R} كما يلي:

$$g_k(x) = x \pm a_k \quad ; \forall k \in \mathbb{N}_n, x \in \mathbb{R}$$

علماً أن $a_k \in \mathbb{R}$ من أجل كل $k \in \mathbb{N}_n$. عندئذ تكون المتغيرات العشوائية الآتية مستقلة أيضاً:

$$Y_k = g_k(X_k) = X_k \pm a_k \quad ; \forall k \in \mathbb{N}_n$$

وذلك لأن الدوال g_k مستمرة على \mathbb{R} من أجل كل $k \in \mathbb{N}_n$ ، ومن ثم ستكون قيوسة بالنسبة إلى \mathcal{R} أيضاً (انظر الملحق B)، ومن ثم بحسب المبرهنة الأخيرة نكون قد أثبتنا صحة ادعائنا.

من التطبيقات المميزة لهذا المثال هو أنه إذا كانت المتغيرات العشوائية X_1, X_2, \dots, X_n مستقلة وتملك عزوماً ابتدائية من المرتبة الأولى، فعندئذ المتغيرات العشوائية:

$$Y_1 = X_1 - EX_1 \quad \& \quad Y_2 = X_2 - EX_2 \quad \& \quad \dots \quad \& \quad Y_n = X_n - EX_n$$

ستكون مستقلة أيضاً، علماً أن EX_i هو التوقع الرياضي (أو القيمة الوسطى) لـ X_i (للاطلاع على مفهوم التوقع الرياضي انظر فقرة العزوم في هذا الفصل).

٢- لتكن X_1, X_2, \dots, X_n متغيرات عشوائية مستقلة فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، ولنأخذ g_1, g_2, \dots, g_n دوال حقيقية معرفة على \mathbb{R} كما يلي:

$$g_k(x) = a_k x^2 \quad ; \forall k \in \mathbb{N}_n, x \in \mathbb{R}$$

علماً أن $a_k \in \mathbb{R}^*$ من أجل كل $k \in \mathbb{N}_n$ ، فعندئذ نلاحظ أن هذه الدوال مستمرة على \mathbb{R} ، ومن ثم تكون قيوسة بالنسبة إلى \mathcal{R} أيضاً، ومنه بحسب المبرهنة الأخيرة ستكون المتغيرات العشوائية الآتية مستقلة أيضاً:

$$Y_k = g_k(X_k) = a_k X_k^2 \quad ; \forall k \in \mathbb{N}_n$$

من التطبيقات المهمة لهذا المثال هو أنه إذا كانت المتغيرات العشوائية X_1, X_2, \dots, X_n مستقلة فإن المتغيرات العشوائية $Y_k = X_k^2$ ستكون مستقلة من أجل كل $k \in \mathbb{N}_n$ أيضاً، وإذا كانت المتغيرات العشوائية X_1, X_2, \dots, X_n تخضع للتوزيع الطبيعي $N(0,1)$ ، فعندئذ المتغير العشوائي $Z := \sum_{i=1}^n X_i^2$ سيكون خاضعاً لتوزيع كاي مربع $\chi^2(n)$ (انظر [65]).

٣- لتكن X_1, X_2, \dots, X_n متغيرات عشوائية مستقلة، ولناخذ $g_k(x) = \frac{x}{a_k}$ من أجل كل $k \in \mathbb{N}_n$ دوال حقيقية معرفة على \mathbb{R} علماً أن $a_k \in \mathbb{R}^*$ من أجل كل $k \in \mathbb{N}_n$ ، فعندئذ نلاحظ أن الدوال $g_k(x) = \frac{x}{a_k}$ مستمرة على \mathbb{R} ، ومن ثم تكون قیوسة بالنسبة إلى \mathcal{R} ، وبحسب المبرهنة الأخيرة تكون المتغيرات العشوائية الآتية مستقلة أيضاً:

$$Y_k = g_k(X_k) = \frac{X_k}{a_k} \quad ; \forall k \in \mathbb{N}_n$$

من التطبيقات المهمة لهذا المثال هو أنه إذا كان X_1 و X_2 متغيرين عشوائيين مستقلين، فإن المتغيرين العشوائيين $Y_1 = X_1$ و $Y_2 = \frac{X_2}{n}$ سيكونان مستقلين أيضاً، علماً أن $n \in \mathbb{N}$ عدد مثبت، وإذا كان X_1 خاضعاً للتوزيع $N(0,1)$ و X_2 خاضعاً لتوزيع $\chi^2(n)$ ، فعندئذ يبرهن على أن المتغير العشوائي:

$$Z := \frac{Y_1}{\sqrt{Y_2}} = \frac{X_1}{\sqrt{X_2}} \sqrt{n}$$

سيكون خاضعاً لتوزيع ستودنت $T(n)$ (انظر [65])، ومن أجل $n=1$ سيصبح Z توزيع كوشي $C(0,1)$.

في الحقيقة يمكن الاستفادة من التوزيعات الهامشية في تبيان إن كانت مجموعة منتهية من المتغيرات العشوائية مستقلة أم لا، وذلك من خلال استخدام المتجهات العشوائية كنقطة انطلاق للدراسة. إن هذه الدراسة تقدمها لنا المبرهنات الآتية التي سنبرهن على إحداها ونقبل الأخريات دون برهان.

(٨, ١, ١, ٧) مبرهنة

ليكن $\mathbb{X}_n = (X_1, X_2, \dots, X_n)$ متجهاً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ بدالة توزيع $F_{\mathbb{X}_n}$ ، فعندئذ تكون المتغيرات العشوائية X_1, X_2, \dots, X_n مستقلة إذا وفقط إذا كان من أجل كل $\vec{x}^n = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$ العلاقة الآتية محققة:

$$F_{\mathbb{X}_n}(\vec{x}^n) = F_{X_1}(x_1) \cdot F_{X_2}(x_2) \cdot \dots \cdot F_{X_n}(x_n) \quad [7,3]$$

علماً أن $F_{X_1}, F_{X_2}, \dots, F_{X_n}$ هي دوال التوزيع الهامشية للمتغيرات العشوائية X_1, X_2, \dots, X_n على الترتيب.

البرهان:

من أجل لزوم الشرط: لدينا المتغيرات العشوائية X_1, X_2, \dots, X_n مستقلة، فعندئذ من أجل كل $\vec{x}^n \in \mathbb{R}^n$ يمكننا أن نكتب الآتي:

$$\begin{aligned} F_{\mathbb{X}_n}(\vec{x}^n) &= P\left(\mathbb{X}_n \in \prod_{k=1}^n (-\infty, x_k)\right) = P(X_1 < x_1, X_2 < x_2, \dots, X_n < x_n) \\ &= P(X_1 < x_1) \cdot P(X_2 < x_2) \cdot \dots \cdot P(X_n < x_n) = F_{X_1}(x_1) \cdot F_{X_2}(x_2) \cdot \dots \cdot F_{X_n}(x_n) \end{aligned}$$

علماً أن:

$$\prod_{k=1}^n (-\infty, x_k) := (-\infty, x_1) \times (-\infty, x_2) \times \dots \times (-\infty, x_n) \in \mathbb{R}^n$$

من أجل كفاية الشرط: يمكننا أن نكتب الآتي من أجل كل $\vec{x}^n \in \mathbb{R}^n$:

$$\begin{aligned}
 F_{\mathbb{X}_n}(\vec{x}^n) &= P\left(\mathbb{X}_n \in \prod_{k=1}^n (-\infty, x_k)\right) \\
 &= P(X_1 \in (-\infty, x_1), X_2 \in (-\infty, x_2), \dots, X_n \in (-\infty, x_n)) \quad (1) \\
 &= P(X_1 \in (-\infty, x_1)) \cdot P(X_2 \in (-\infty, x_2)) \cdot \dots \cdot P(X_n \in (-\infty, x_n))
 \end{aligned}$$

ومن جهة أخرى لدينا من أجل كل $\vec{x}^n \in \mathbb{R}^n$ ما يلي مُحَقَّقاً أيضاً:

$$\begin{aligned}
 F_{X_1}(x_1) \cdot F_{X_2}(x_2) \cdot \dots \cdot F_{X_n}(x_n) &= P(X_1 < x_1) \cdot P(X_2 < x_2) \cdot \dots \cdot P(X_n < x_n) \\
 &= P(X_1 \in (-\infty, x_1)) \cdot P(X_2 \in (-\infty, x_2)) \cdot \dots \cdot P(X_n \in (-\infty, x_n)) \quad (2)
 \end{aligned}$$

ومن ثم ينتج من العلاقتين (1) و (2) واستخدام الفرض (تَحَقُّقُ العلاقة [7,3]) أنه من أجل كل $\vec{x}^n \in \mathbb{R}^n$ ستكون العلاقة الآتية مُحَقَّقَةً أيضاً:

$$\begin{aligned}
 P\left(\mathbb{X}_n \in \prod_{k=1}^n (-\infty, x_k)\right) &= P(X_1 \in (-\infty, x_1)) \cdot P(X_2 \in (-\infty, x_2)) \cdot \dots \cdot P(X_n \in (-\infty, x_n)) \\
 \text{وهذا يعني بحسب تعريف الاستقلال أن المتغيرات العشوائية } X_1, X_2, \dots, X_n &\text{ مستقلة.}
 \end{aligned}$$

(٧, ١, ١, ٩) مبرهنة (تقبل دون برهان)

ليكن $\mathbb{X}_n = (X_1, X_2, \dots, X_n)$ متجهاً عشوائياً متقطعاً، فعندئذٍ تَحَقُّقُ الشرط الآتي:

$$P_{i_1 i_2 \dots i_n} = P_{i_1 \dots i_1} \cdot P_{i_2 \dots i_2} \cdot \dots \cdot P_{i_n \dots i_n} \quad [7,4]$$

هو شرط لازم وكاف لاستقلال المتغيرات العشوائية X_1, X_2, \dots, X_n المكونة لمركبات هذا المتجه العشوائي.

(٧, ١, ١, ١٠) مبرهنة (تقبل دون برهان)

لتكن X_1, X_2, \dots, X_n متغيرات عشوائية متقطعة مجموعة قيمها على الترتيب هي:

$$\mathbf{X}_1 = \{x_{i_1}; i_1 \in I_1\} \quad \& \quad \mathbf{X}_2 = \{x_{i_2}; i_2 \in I_2\} \quad \& \dots \& \quad \mathbf{X}_n = \{x_{i_n}; i_n \in I_n\}$$

وبفرض أن:

$$p_{i_1} = P(X = x_{i_1}) \quad ; i_1 \in I_1 \quad \& \quad p_{i_2} = P(X = x_{i_2}) \quad ; i_2 \in I_2 \quad \& \dots \& \quad p_{i_n} = P(X = x_{i_n}) \quad ; i_n \in I_n$$

وكذلك:

$$p_{i_1 i_2 \dots i_n} = P(X = x_{i_1}, X = x_{i_2}, \dots, X = x_{i_n})$$

فعندئذٍ تَحَقُّقُ العلاقة الآتية من أجل كل $i_1 \in I_1, i_2 \in I_2, \dots, i_n \in I_n$:

$$p_{i_1 i_2 \dots i_n} = p_{i_1} \cdot p_{i_2} \cdot \dots \cdot p_{i_n} \quad [7,5]$$

هو شرط لازم وكاف لاستقلال المتغيرات العشوائية X_1, X_2, \dots, X_n .

(٧, ١, ١, ١١) مبرهنة

لتكن X_1, X_2, \dots, X_n متغيرات عشوائية مستمرة بدوال كثافة احتمالية $f_{X_1}, f_{X_2}, \dots, f_{X_n}$ على الترتيب، فعندئذٍ إذا كانت دالة الكثافة المشتركة f_{X_1, X_2, \dots, X_n} مُعطاة (أو أمكن تعيينها)، فإن تَحَقُّقُ العلاقة الآتية من أجل كل $(x_1, x_2, \dots, x_n) \in \mathbb{R}^n$:

$$f_{X_1, X_2, \dots, X_n}(x_1, x_2, \dots, x_n) = f_{X_1}(x_1) \cdot f_{X_2}(x_2) \cdot \dots \cdot f_{X_n}(x_n)$$

هو شرط لازم وكاف لاستقلال المتغيرات العشوائية X_1, X_2, \dots, X_n .

(٧, ١, ١, ١٢) مبرهنة

ليكن $\mathbb{X}_n = (X_1, X_2, \dots, X_n)$ متجهاً عشوائياً مستمراً بدالة كثافة $f_{\mathbb{X}_n}$ ، فعندئذ تحقق العلاقة الآتية من أجل كل $\mathbb{R}^n \ni \vec{x}^n = (x_1, x_2, \dots, x_n)$

$$f_{\mathbb{X}_n}(\vec{x}^n) = f_1(x_1) \cdot f_2(x_2) \cdot \dots \cdot f_n(x_n) \quad [7,6]$$

هو شرط لازم وكاف لاستقلال المتغيرات العشوائية X_1, X_2, \dots, X_n المكونة لمركبات \mathbb{X}_n ، علماً أن f_1, f_2, \dots, f_n هي دوال الكثافة الهامشية للمتغيرات العشوائية X_1, X_2, \dots, X_n على الترتيب.

(٧, ١, ١, ١٣) أمثلة

١- بالعودة إلى المثال / ١ / من (٥-٥-٢-٤) نجد أن المتغيرين العشوائيين X و Y الذين يكونان مركبات المتجه $\mathbb{X}_2 = (X, Y)$ غير مستقلين بسبب أنه لدينا:

$$p_{11} = \frac{7}{21} = 0.333 \neq p_{1\bullet} \cdot p_{\bullet 1} = \frac{11}{21} \cdot \frac{14}{21} = \frac{154}{441} = 0.349$$

وبالطبع هذا كاف للحكم على عدم الاستقلال بين مركبات المتجه $\mathbb{X}_2 = (X, Y)$.

٢- بالعودة إلى المثال / ٢ / من (٥-٥-٢-٤) نجد أن المتغيرين العشوائيين X و Y الذين يكونان مركبات المتجه $\mathbb{X}_2 = (X, Y)$ مستقلان، وذلك لأنه من أجل أي $x, y \in \mathbb{R}$ لدينا:

$$f_{\mathbb{X}_2}(x, y) = f_1(x) \cdot f_2(y)$$

علماً أن f_1 و f_2 هما دالتي الكثافة الاحتمالية الهامشيتين لـ X و Y على الترتيب. كذلك يمكن استنتاج الاستقلال بين X و Y من خلال تحقق العلاقة الآتية أيضاً:

$$F_{\mathbb{X}_2}(x, y) = F_X(x) \cdot F_Y(y) \quad ; \forall x, y \in \mathbb{R}$$

علماً أن F_X و F_Y هما دالتي التوزيع الهامشيتين لـ X و Y على الترتيب.

(٧, ١, ٢) الاستقلال لعدد غير منته من المتغيرات العشوائية

في هذه الفقرة سنقدم مفهوم الاستقلال لعدد غير منته من المتغيرات العشوائية (ولكن وبشكل موجز).

(٧, ١, ٢, ١) تعريف (الاستقلال لعدد غير منته من المتغيرات العشوائية)

لتكن $\mathbb{R} \supseteq T$ مجموعة غير خالية وليست منتهية (قد تكون غير قابلة للعد) أيضاً، ولنأخذ أسرة متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ يقال عن أسرة المتغيرات العشوائية $\{X_t\}_{t \in T}$ إنها **مستقلة** (أو **مستقلة في مجموعة الأساس** لها Ω) إذا كان من أجل أية مجموعة جزئية منتهية $T \supseteq \{t_1, t_2, \dots, t_n\}$ لدينا العلاقة الآتية مُحَقَّقة من أجل أية حوادث $A_{t_1}, A_{t_2}, \dots, A_{t_n}$ من \mathcal{A} :

$$P(X_{t_1} \in A_{t_1}, X_{t_2} \in A_{t_2}, \dots, X_{t_n} \in A_{t_n}) = \prod_{k=1}^n P(X_{t_k} \in A_{t_k})$$

(٢, ٢, ١, ٧) مثال

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، علماً أن:

$$\Omega = [0, 1] \quad \& \quad \mathcal{A} = [0, 1] \cap \mathbb{R} \quad \& \quad P(A) = \int_A dx \quad ; \forall A \in \mathcal{A}$$

أي إنه لدينا الفضاء الاحتمالي للتوزيع المنتظم المستمر على الفترة $[0, 1]$ ، ولنفترض أن X متغير عشوائي فوق $[\Omega, \mathcal{A}, P]$ يمثل عدداً عشوائياً في نظام العد الثنائي، أي إن $X = 0.\alpha_1 \alpha_2 \alpha_3 \dots \alpha_n \dots$ مع $\alpha_k(\omega) \in \{0, 1\}$ من أجل كل $k \in \mathbb{N}$ و $\omega \in \Omega$ ، ولنثبت استقلال المتغيرات العشوائية $\alpha_1, \alpha_2, \dots$

من أجل ذلك لنأخذ n متغيراً عشوائياً من الأسرة $\{\alpha_k ; k \in \mathbb{N}\}$ علماً أن $n \in \mathbb{N}$ كفي و لكنه مُثبت، ولنقم بإعادة ترقيم هذه المتغيرات العشوائية بالشكل $\alpha_1, \alpha_2, \dots, \alpha_n$ ، ولنثبت استقلال هذه المتغيرات العشوائية على النحو الآتي:

من المعلوم أن أي عدد $x \in [0, 1]$ يكتب في نظام العد الثنائي وفقاً للعلاقة $x = \sum_{k=1}^{\infty} \alpha_k 2^{-k}$ ، ومن ثم كل قيمة x تُعين متتالية متغيرات عشوائية $(\alpha_k)_{k \in \mathbb{N}}$ ، ومنه يكون من أجل أية قيم x_1, x_2, \dots, x_n من المجموعة $\{0, 1\}$ لدينا العلاقة الآتية مُحَقَّقة:

$$P(\alpha_1 = x_1, \alpha_2 = x_2, \dots, \alpha_n = x_n) = P\left(x = \sum_{k=1}^n x_k 2^{-k} + \sum_{k=n+1}^{\infty} x_k^* 2^{-k} \quad ; \quad x_k^* \text{ is arbitrary} \right)$$

$$= P\left(\underbrace{\sum_{k=1}^n x_k 2^{-k}}_{\text{for } x_i^*=0} \leq x \leq \underbrace{\sum_{k=1}^n x_k 2^{-k} + \sum_{k=n+1}^{\infty} 2^{-k}}_{\text{for } x_i^*=1}\right)$$

ولكن يمكننا أن نكتب الآتي:

$$\sum_{k=n+1}^{\infty} 2^{-k} = \sum_{k=n+1}^{\infty} 2^{-(k-n-1)-n-1} = 2^{-n-1} \sum_{k=0}^{\infty} 2^{-k} = 2^{-n-1} \cdot 2 = 2^{-n}$$

ولذلك ينتج لدينا أن:

$$P\left(\sum_{k=1}^n x_k 2^{-k} \leq x \leq \sum_{k=1}^n x_k 2^{-k} + \sum_{k=n+1}^{\infty} 2^{-k}\right) = \sum_{k=n+1}^{\infty} 2^{-k} = 2^{-n}$$

وهكذا أصبح لدينا:

$$P(\alpha_1 = x_1, \alpha_2 = x_2, \dots, \alpha_n = x_n) = 2^{-n} \quad (1)$$

ومن جهة أخرى نجد أنه من أجل كل $k \in \mathbb{N}$ لدينا العلاقة $P(\alpha_k = x_k) = \frac{1}{2}$ مُحَقَّقة من أجل أي $x_k \in \{0, 1\}$ ، ومن ثم يكون:

$$\prod_{k=1}^n P(\alpha_k = x_k) = \left(\frac{1}{2}\right)^n = 2^{-n} \quad (2)$$

وبالتالي نجد من (1) و (2) أن:

$$P(\alpha_1 = x_1, \alpha_2 = x_2, \dots, \alpha_n = x_n) = \prod_{k=1}^n P(\alpha_k = x_k)$$

وهذا يعني أن المتغيرات العشوائية $\alpha_1, \alpha_2, \dots, \alpha_n$ مستقلة من أجل أي $n \in \mathbb{N}$ ، وبالنسبة تكون أسرة المتغيرات العشوائية $\{\alpha_k ; k \in \mathbb{N}\}$ مستقلة أيضاً، وبهذا يكون قد تم إثبات الاستقلال.

(٧, ٢) العزوم للمتغيرات العشوائية

Moments of random variables

لقد لاحظنا في الفصل الثاني أن آية مجموعة من البيانات سيكون لها عدة سمات عددية تميزها منها مقياس النزعة المركزية، التشتت والشكل. كذلك الأمر بالنسبة إلى المتغيرات العشوائية، فلها سمات عددية تميزها أيضاً، ولكن بسبب أن اهتمامنا في الفصلين السابقين كان منصباً على معرفة نوع المتغير العشوائي وتعيين توزيعه الاحتمالي، وحساب احتمالات لحوادث متعلقة بالمتغير العشوائي دون الاهتمام بسلوك القيم التي يأخذها المتغير العشوائي، فإننا سنقوم بتقديم بعض المقياس العددية للمتغيرات العشوائية التي تعد بمثابة سمات مميزة للمتغيرات العشوائية أيضاً.

من جهة أخرى قد يكون تعيين دالة التوزيع الاحتمالية لمتغير عشوائي عسيراً أو غير ممكن وفقاً للتعريف المعطى لدالة التوزيع الاحتمالية، ولهذا السبب كان لا بد من البحث عن طرائق أخرى تساعدنا في ذلك، وفي هذا الصدد لوحظ أن ما يُعرف باسم **الدوال المولدة الاحتمالية** (التي ينتج عنها كحالة خاصة الدوال المولدة للعزوم) وكذلك **الدوال المميزة** أثبتت فعالية كبيرة في مثل هذه الحالات. لكن مفهوم الدوال المولدة وكذلك الدوال المميزة يعتمد في تعريفه على مفهوم العزوم للمتغير العشوائي أيضاً، ولذلك كان من الضرورة تقديم مفهوم العزوم للمتغيرات العشوائية أولاً، والتعرف على أهم خصائصها، ومن ثم الانتقال إلى مفهومي الدوال المولدة والدوال المميزة للمتغيرات العشوائية.

قبل الانتقال إلى تقديم العزوم نشير هنا إلى أننا سنقوم بحساب بعض القيم المميزة لبعض المتغيرات العشوائية الشهيرة التي ذكرناها في هذا الكتاب، ومن يود الاطلاع على بقية القيم المميزة التي سنتعامل معها من أجل بقية المتغيرات العشوائية الشهيرة السابق ذكرها يمكنه الرجوع إلى جدول لبعض التوزيعات الاحتمالية الشهيرة المقدم في نهاية هذا الكتاب.

(٧, ٢, ١) العزم الابتدائي من المرتبة k لمتغير عشوائي Moment of Order k of a Random Variable

إن أول سمة مميزة لمتغير عشوائي هي ما يُعرف باسم **القيمة الوسطى** للمتغير العشوائي التي سنشرحها من أجل متغير عشوائي متقطع بسيط وذلك على سبيل التبسيط والتوضيح.

(٧, ٢, ١, ١) مفهوم القيمة الوسطى لمتغير عشوائي

ليكن X متغيراً عشوائياً متقطعاً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ بمجموعة قيم $X = \{x_i; i \in I\}$ مع I مجموعة منتهية (أي إن X متغير عشوائي بسيط)، فعندئذ يفرض أن:

$$Z_i = \{\omega \in \Omega; X(\omega) = x_i\} \quad ; \forall i \in I$$

فإنه (وكما بيّنا في الفصل الخامس) يمكننا أن نكتب:

$$X(\omega) = \sum_{i \in I} x_i \cdot \mathbf{I}_{Z_i}(\omega) \quad ; \forall \omega \in \Omega$$

فعندئذ لو قمنا بتكرار التجربة العشوائية التي قيد الدرس (وتحت الشروط نفسها، وبشكل مستقل كل منها عن الأخرى) لـ n مرة متتالية، فإننا سنتوقع ظهور القيمة x_i عدداً من المرات يساوي على وجه التقريب $n \cdot p_i$ وذلك من أجل كل $i \in I$ (علماً أن $p_i = P(X = x_i)$)، ومن ثم القيمة الوسطى (أو المتوسط، أو القيمة المتوقعة الحصول عليها) لقيم هذا المتغير العشوائي المبنية على نتائج الـ n تجربة المنفذة هو على وجه التقريب:

$$\frac{x_1 n p_1 + x_2 n p_2 + \dots + x_{|I|} n p_{|I|}}{n} = \sum_{i \in I} x_i p_i$$

وهنا نلاحظ أن هذه النتيجة جاءت منسجمة مع مفهوم المتوسط الموزون الذي قُدم في الفصل الثاني، ولكن هنا من أجل متغير عشوائي،

حيث لدينا الأوزان $w_1 = n \cdot p_1, w_2 = n \cdot p_2, \dots, w_{|I|} = n \cdot p_{|I|}$ و $x_1, x_2, \dots, x_{|I|}$ على الترتيب. إذاً، فالقيمة الوسطى للمتغير عشوائي تُعبر عن مركز ثقل مجموعة قيمه أيضاً.

في الواقع إن القيمة الوسطى للمتغير عشوائي هي حالة خاصة مما يدعى بـ **العزوم** للمتغير عشوائي، ولذلك سنقوم أولاً بتقديم مفاهيم تتعلق بالعزوم للمتغير عشوائي والتعرف على أهم الخصائص المتعلقة بها.

(٧, ٢, ١, ٢) تعريف العزم الابتدائي من المرتبة k للمتغير عشوائي

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، و k عدداً صحيحاً موجباً، فعندئذ **العزم الابتدائي من المرتبة k** للمتغير العشوائي X (سنرمز له بـ $\mu_X^{(k)}$) يُحسب على النحو الآتي:

١- إذا كان X متقطعاً بمجموعة قيم $X = \{x_i; i \in I\}$ فإن:

$$\mu_X^{(k)} = \sum_{i \in I} x_i^k \cdot P(X = x_i) \quad [7,7-a]$$

٢- إذا كان X مستمراً بدالة كثافة احتمالية f_X فإن:

$$\mu_X^{(k)} = \int_{-\infty}^{+\infty} x^k f_X(x) dx \quad [7,7-b]$$

(٧, ٢, ١, ٣) ملاحظات

١- في حال كانت الدراسة متعلقة بمتغير عشوائي واحد فقط (ومن ثم لا مجال للالتباس في هذه الحالة)، فإننا سنكتب $\mu^{(k)}$ عوضاً عن $\mu_X^{(k)}$ وذلك على سبيل التبسيط.

٢- عندما يكون $k = 1$ سنكتب $\mu := \mu^{(1)}$ ، وفي هذه الحالة الخاصة يُقال عن μ إنه **التوقع الرياضي** Mathematical Expectation للمتغير العشوائي X ، وعادةً يُرمز له بـ EX أيضاً (استخدم الرمز E كأول حرف من كلمة **Expectation**)، أي إن $\mu = EX$ ، وقياساً عليه يُقال عن EX^k إنه التوقع الرياضي للمتغير العشوائي X^k ، ومنه يكون $\mu^{(k)} = EX^k$ ، ومن ثم يمكننا أن نكتب $\mu^{(k)}$ على النحو الآتي:

$$\mu^{(k)} = EX^k = \begin{cases} \sum_{i \in I} x_i^k \cdot P(X = x_i) & \text{for } X \text{ discrete} \\ \int_{\mathbb{R}} x^k \cdot f_X(x) dx & \text{for } X \text{ continuous} \end{cases} \quad [7,7-c]$$

٣- كما هو ملاحظ فإن EX^k هو قيمة عددية، وقد تكون قيمته تساوي $\pm \infty$ عندما يكون $\sum_{i \in I} x_i^k P(X = x_i)$ متباعداً أو $\int_{-\infty}^{+\infty} x^k f_X(x) dx$ متباعداً، ولذلك يُقال إن المتغير العشوائي X يملك عزماً ابتدائياً من المرتبة k إذا كان:

$$E|X|^k < +\infty \quad [7,8]$$

٤- إذا كانت g دالة حقيقية معرفة على \mathbb{R} وقيوسة بالنسبة إلى \mathcal{R} ، فعندئذ تكون الدالة $g(X)$ متغيراً عشوائياً أيضاً، ولذلك يُقال عن $E[g(X)^k]$ إنه العزم الابتدائي من المرتبة k لـ $g(X)$ أو التوقع الرياضي لـ $g(X)^k$ ، حيث يكون لدينا:

$$a) \quad E[g(X)^k] = \sum_{i \in I} [g(x_i)]^k \cdot P(X = x_i) \quad [7,9-a]$$

إذا كان X متغيراً عشوائياً متقطعاً بمجموعة قيم $X = \{x_i; i \in I\}$.

$$\text{b) } \mathbf{E} [g(X)]^k = \int_{-\infty}^{+\infty} [g(x)]^k \cdot f_X(x) dx \quad [7,9-b]$$

إذا كان X متغيراً عشوائياً مستمراً بدالة كثافة احتمالية f_X .

أما وجودية $\mathbf{E} [g(X)]^k$ فإنه مرهونة بالتقارب المطلق للمتسلسلة العددية [7,9-a] أو للتكامل المعتل [7,9-b]، وهنا نلاحظ أنه في الحالة الخاصة عندما تكون g دالة المطابقة على \mathbb{R} (أي إن $g(x) = x$)، فإنه يصبح لدينا $\mathbf{E}[g(X)] = \mathbf{E}X$ هو التوقع الرياضي للمتغير العشوائي X نفسه.

٥- يبرهن (سنقبلها دون برهان) على أنه إذا كان X متغيراً عشوائياً يملك عزمًا ابتدائياً من المرتبة k مع $k \in \mathbb{N}$ (أي إن $\mu^{(k)}$ موجوداً)، فإن العزوم الابتدائية $\mu^{(\ell)}$ ستكون موجودة من أجل كل قيم ℓ المحققة للمتباعدة $1 \leq \ell < k$ ، وتكون المتباعدة الآتية محققة أيضاً:

$$\sqrt[\ell]{\mathbf{E}|X|^\ell} \leq \sqrt[k]{\mathbf{E}|X|^k}$$

وبناءً على هذه المقولة، فإذا كان X متغيراً عشوائياً لا يملك عزمًا ابتدائياً من المرتبة k فإنه لن يملك أي عزم ابتدائي من مرتبة $k < m$.

(٤، ١، ٢، ٧) أمثلة

١- ليكن $[\Omega, \mathcal{A}, P]$ الفضاء الاحتمالي الموافق لتجربة إلقاء حجر نرد متوازن لمرة واحدة فقط، وليكن X متغيراً عشوائياً فوق هذا الفضاء الاحتمالي معرفاً من خلال العلاقة $X(\omega) = \omega$ ، ولنبين إن كان هذا المتغير العشوائي يملك عزمًا ابتدائياً من المرتبة الأولى والثانية أم لا؟

الحل: من أجل ذلك نلاحظ أن هذا المتغير العشوائي متقطع ومجموعة قيمه هي $X = \{1, 2, 3, 4, 5, 6\}$ ، ومن ثم يكون

لدينا:

$$\mathbf{E}X = \sum_{i \in I} x_i \cdot P(X = x_i) = \sum_{k=1}^6 k \cdot P(X = k) = \sum_{k=1}^6 k \cdot \frac{1}{6} = \frac{1}{6} \sum_{k=1}^6 k = \frac{21}{6} = 3.5$$

وكذلك نجد أن:

$$\mathbf{E}X^2 = \sum_{i \in I} x_i^2 \cdot P(X = x_i) = \sum_{k=1}^6 k^2 \cdot P(X = k) = \frac{1}{6} \sum_{k=1}^6 k^2 = \frac{91}{6} = 15.17$$

وبحساب العزوم المطلقة نجد ما يلي:

$$\mathbf{E}|X| = \sum_{i \in I} |x_i| \cdot P(X = x_i) = \sum_{k=1}^6 |k| \cdot P(X = k) = \frac{1}{6} \sum_{k=1}^6 k = 3.5 < +\infty$$

ومن ثم المتغير العشوائي X يملك عزمًا ابتدائياً من المرتبة الأولى (يملك توقعاً رياضياً)، وكذلك لدينا:

$$\mathbf{E}|X|^2 = \sum_{i \in I} |x_i|^2 \cdot P(X = x_i) = \sum_{k=1}^6 |k|^2 \cdot P(X = k) = \frac{1}{6} \sum_{k=1}^6 k^2 = 15.17 < +\infty$$

ومن ثم المتغير العشوائي X يملك عزمًا ابتدائياً من المرتبة الثانية أيضاً، وبشكل مماثل يمكننا تبيان أن X يملك عزمًا ابتدائياً من مختلف المراتب $k \in \mathbb{N}$.

٢- تحت فرضيات المثال السابق / ١ / سنأخذ g دالة حقيقية معرفة على \mathbb{R} من خلال العلاقة $g(x) := 2x + 1$ ، ولنبين

إن كان المتغير العشوائي $Y = g(X)$ يملك عزمًا ابتدائياً من المرتبة الأولى أم لا؟

الحل: من الملاحظ أنَّ $g(X) = 2X + 1$ هو متغير عشوائي متقطع أيضاً لأنَّ الدالة المُعطاة g مستمرة على \mathbb{R} ، ولدينا X متغير عشوائي متقطع بالفرض، ولذلك يمكننا أن نكتب الآتي:

$$\mathbf{E} Y = \mathbf{E} [g(X)] = \sum_{i \in I} g(x_i) P(X = x_i) = \sum_{k=1}^6 (2k+1) \frac{1}{6} = \frac{1}{6} \sum_{k=1}^6 (2k+1) = \frac{48}{6} = 8$$

ومن جهة أخرى لدينا:

$$\mathbf{E} |Y| = \mathbf{E} |g(X)| = \sum_{i \in I} |g(x_i)| \cdot P(X = x_i) = \sum_{k=1}^6 |2k+1| \frac{1}{6} = \frac{1}{6} \sum_{k=1}^6 (2k+1) = \frac{48}{6} = 8 < +\infty$$

ومن ثمَّ المتغير العشوائي $Y = g(X)$ يملك عزماً ابتدائياً من المرتبة الأولى (يملك توقعاً رياضياً)، وبشكل مماثل يمكننا تبين أنَّ $Y = g(X)$ يملك عزوفاً ابتدائيةً من مختلف المراتب $\mathbb{N} \ni k$.

٣- ليكن X متغيراً عشوائياً بحيث $X \sim U(a, b)$ ، ولنبيِّن إن كان هذا المتغير العشوائي يملك عزوفاً ابتدائيةً من المرتبة الأولى والثانية أم لا؟

الحل: نعلم أنَّ هذا المتغير العشوائي مستمرٌّ بدالة كثافة احتمالية:

$$f_X(x) = \frac{1}{b-a} \mathbf{I}_{[a,b]}(x) \quad ; \forall x \in \mathbb{R}$$

مع $-\infty < a < b < +\infty$ ثوابت، ومن ثمَّ يكون لدينا:

$$\mathbf{E}(X) = \int_{-\infty}^{\infty} x \cdot f_X(x) dx = \int_a^b \frac{1}{b-a} x dx = \frac{1}{b-a} \left[\frac{b^2 - a^2}{2} \right] = \frac{a+b}{2}$$

وكذلك نجد:

$$\mathbf{E} |X| = \int_{-\infty}^{\infty} |x| f_X(x) dx = \frac{1}{b-a} \int_a^b |x| dx < +\infty$$

وذلك لأنَّه:

$$\int_a^b |x| dx = \int_a^b x dx = \frac{b^2 - a^2}{2} < +\infty \quad \text{أ- من أجل } 0 < a \text{ لدينا:}$$

$$\int_a^b |x| dx = \int_a^0 -x dx + \int_0^b x dx = \frac{a^2 + b^2}{2} < +\infty \quad \text{ب- من أجل } 0 > a \text{ و } 0 < b \text{ لدينا:}$$

$$\int_a^b |x| dx = \int_a^b -x dx = \frac{a^2 - b^2}{2} < +\infty \quad \text{ج- من أجل } 0 > b \text{ لدينا:}$$

ومن ثمَّ المتغير العشوائي X يملك عزماً ابتدائياً من المرتبة الأولى (يملك توقعاً رياضياً)، وكذلك نجد أنَّ المتغير العشوائي X يملك عزماً ابتدائياً من المرتبة الثانية أيضاً، حيث لدينا:

$$\mathbf{E} |X|^2 = \int_{-\infty}^{\infty} |x|^2 \cdot f_X(x) dx = \frac{1}{b-a} \int_a^b x^2 dx = \frac{b^3 - a^3}{3(b-a)} = \frac{(b^2 + ab + a^2)}{3} < +\infty$$

وبشكل مماثل يمكننا تبين أنَّ X يملك عزوفاً ابتدائيةً من مختلف المراتب $\mathbb{N} \ni k$.

٤- تحت فرضيات المثال السابق / ٣ / سنأخذ g دالة حقيقية معرفة على \mathbb{R} من خلال العلاقة $g(x) := 2x + 1$ ، ولنبين إن كان المتغير العشوائي $Y = g(X)$ يملك عزماً ابتدائياً من المرتبة الأولى أم لا؟

الحل: نلاحظ أن المتغير العشوائي Y مستمر لأن الدالة $g(x) := 2x + 1$ مستمرة، ولدينا X متغير عشوائي مستمر بالفرض، ومن ثم يكون:

$$E[Y] = E[g(X)] = \int_{-\infty}^{\infty} g(x) \cdot f_X(x) dx = \int_a^b \frac{1}{b-a} (2x+1) dx = \frac{1}{b-a} \left[(b^2 - a^2) + (b-a) \right] = b + a + 1$$

وبما أن $-\infty < a < b < +\infty$ فإنه ينتج لدينا أن $E[g(X)] < +\infty$ ، وهذا يعني أن المتغير العشوائي $Y = 2X + 1$ يملك عزماً ابتدائياً من المرتبة الأولى (يملك توقعاً رياضياً)، وبشكل مماثل يمكننا تبيان أن Y يملك عزماً ابتدائياً من مختلف المراتب $N \ni k$.

أما إذا أردنا حساب $E(Y)$ من خلال تعيين $f_Y(y)$ فإننا نجد من أجل كل y من \mathbb{R} ما يلي:

$$F_Y(y) = F_X\left(\frac{y-1}{2}\right) = \int_{-\infty}^{\frac{y-1}{2}} \frac{1}{b-a} I_{[a,b]}(t) dt = \int_{-\infty}^y \underbrace{\frac{1}{2(b-a)} I_{[a,b]} \left(\frac{y-1}{2} \right)}_{f_Y(y)} dy$$

والتي ينتج عنها أن:

$$f_Y(y) = \frac{1}{2(b-a)} I_{[a,b]} \left(\frac{y-1}{2} \right)$$

ومن ثم يكون لدينا:

$$\begin{aligned} EY &= \int_{-\infty}^{\infty} y \cdot f_Y(y) dy = \frac{1}{2(b-a)} \int_{-\infty}^{\infty} y \cdot I_{[a,b]} \left(\frac{y-1}{2} \right) dy = \frac{1}{2(b-a)} \int_{-\infty}^{\infty} y \cdot I_{[2a+1, 2b+1]}(y) dy \\ &= \frac{1}{2(b-a)} \left[\underbrace{\int_{-\infty}^{2a+1} y \cdot I_{[2a+1, 2b+1]}(y) dy}_{=0} + \int_{2a+1}^{2b+1} y \cdot I_{[2a+1, 2b+1]}(y) dy + \underbrace{\int_{2b+1}^{+\infty} y \cdot I_{[2a+1, 2b+1]}(y) dy}_{=0} \right] \\ &= \frac{1}{2(b-a)} \int_{2a+1}^{2b+1} y dy = \frac{1}{2(b-a)} \cdot \frac{y^2}{2} \Big|_{2a+1}^{2b+1} = \frac{1}{2(b-a)} \cdot \frac{4(b^2 - a^2) + 4(b-a)}{2} \end{aligned}$$

ومنه ينتج لدينا الآتي (وهي ذات النتيجة التي حصلنا عليها سابقاً):

$$EY = \frac{1}{2(b-a)} \cdot \frac{4(b-a) [(b+a)+1]}{2} = b + a + 1$$

٥- ليكن $X \sim C(0,1)$ (خاضع توزيع كوشي)، ولنبين إن كان هذا المتغير العشوائي يملك عزماً ابتدائياً من المرتبة الأولى أم لا؟

الحل: نعلم أن لهذا المتغير العشوائي دالة كثافة احتمالية تُعطى من خلال العلاقة الآتية (انظر العلاقة [6-14-a]):

$$f_X(x) = \frac{1}{\pi(1+x^2)} \quad ; \forall x \in \mathbb{R}$$

ومن ثم يكون لدينا:

$$\begin{aligned} \mathbf{E} |X| &= \int_{-\infty}^{\infty} |x| f_X(x) dx = \int_{-\infty}^{\infty} |x| \frac{1}{\pi(1+x^2)} dx = \frac{1}{\pi} \left[\int_{-\infty}^0 \frac{-x}{1+x^2} dx + \int_0^{\infty} \frac{x}{1+x^2} dx \right] \\ &= \frac{1}{\pi} \int_0^{\infty} \frac{2x}{1+x^2} dx \stackrel{y=1+x^2}{=} \frac{1}{\pi} \int_1^{\infty} \frac{dy}{y} = \frac{1}{\pi} \left[\ln y \right]_1^{\infty} = +\infty \end{aligned}$$

أي إن $\mathbf{E} |X| = +\infty$ ، وهذا يعني أن المتغير العشوائي الخاضع لتوزيع كوشي لا يملك عزماً ابتدائياً من المرتبة الأولى، ومن ثم فإنه لا يملك عزوماً ابتدائيةً ولا من أية مرتبة.

(٧, ٢, ١, ٥) ملاحظة

من المثال الأول في الفقرة السابقة وجدنا $\mathbf{E}X = \frac{21}{6}$ ، ومن ثم يكون لدينا:

$$g(\mathbf{E}X) = g\left(\frac{21}{6}\right) = 2 \cdot \frac{21}{6} + 1 = \frac{48}{6} = 8$$

ومن ثم يكون لدينا من أجل هذا المثال ما يلي محققاً:

$$\mathbf{E}[g(X)] = g(\mathbf{E}X)$$

ولكن يجب الانتباه إلى أنه في الحالة العامة لدينا:

$$\mathbf{E}[g(X)] \neq g(\mathbf{E}X)$$

ولكن عندما تتمتع الدالة g ببعض الخصائص فثمة علاقة مُحَدَّدة بين طرفي العلاقة السابقة، وهذا ما تقدمه لنا المبرهنة الآتية التي سنقبلها دون برهان.

(٧, ٢, ١, ٦) مبرهنة (متباينة جينسين Jensen inequality)

لتكن g دالة حقيقية مستمرة على \mathbb{R} ، وليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ:

١- إذا كانت الدالة g محدبة على \mathbb{R} فإنه يكون لدينا:

$$\mathbf{E}[g(X)] \geq g(\mathbf{E}X) \quad [7,10-a]$$

٢- إذا كانت الدالة g مقعرة على \mathbb{R} فإنه سيكون لدينا:

$$\mathbf{E}[g(X)] \leq g(\mathbf{E}X) \quad [7,10-b]$$

إن كلا من المتباينتين السابقتين تُعرف باسم **متباينة جينسين** نسبة إلى الرياضياتي والمهندس الدانماركي **جينسين** Johan Ludwig William Valdemar Jensen (1859-1925).

لاحظ أن المساواة تتحقق من أجل بعض الحالات في كلا المتباينتين السابقتين، ومنها الحالة التي تكون فيها g مُعطاة من خلال العلاقة $y = g(x) = 2x + 1$ التي عرضناها سابقاً حيث نعلم أن هذه الدالة تُحقق تعريف الدالة المحدبة والمقعرة بأن واحد (من أجل الاطلاع على تعريف الدالة المحدبة والمقعرة راجع الملحق A).

(٧, ٢, ١, ٧) أمثلة

١- لنأخذ X متغيراً عشوائياً كما في المثال ١ / من الفقرة (٧, ٢, ١, ٤)، ولنأخذ g دالة حقيقية معرفة على \mathbb{R} من خلال العلاقة $g(x) = e^{2x}$ ، فنلاحظ أن الدالة g مستمرة على \mathbb{R} ، ولذلك فإن $g(X)$ هو متغير عشوائي (متقطع لأن X متقطع)، وكذلك نجد أن g محدبة على \mathbb{R} ، ومن ثم يمكننا أن نكتب الآتي:

$$E[g(X)] = \sum_{i \in I} g(x_i)P(X = x_i) = \sum_{k=1}^6 e^{2k} \frac{1}{6} = \frac{1}{6} \sum_{k=1}^6 e^{2k} = \frac{188227.631}{6} = 31371.272$$

ولكن وجدنا سابقاً $EX = 3.5$ ، ومن ثم يكون لدينا $E[g(X)] = e^7 = 1096.333$ ، والتي نجد منها أن:

$$g[E(X)] < E[g(X)]$$

٢- مرة أخرى لنأخذ X متغيراً عشوائياً كما في المثال ١ / من الفقرة (٤, ١, ٢, ٧)، وسنأخذ g دالة حقيقية معرفة على \mathbb{R}^+ من خلال العلاقة $g(x) = \sqrt{x}$ ، فنجد أن الدالة g مستمرة ومقعرّة على \mathbb{R}^+ ، فينتج بسبب استمرار الدالة g أن $g(X) := \sqrt{X}$ متغير عشوائي متقطع، ومن ثم يمكننا أن نكتب الآتي:

$$E[g(X)] = \sum_{i \in I} g(x_i)P(X = x_i) = \sum_{k=1}^6 \sqrt{k} \frac{1}{6} = \frac{1}{6} \sum_{k=1}^6 \sqrt{k} = \frac{10.832}{6} = 1.805$$

ولكن لدينا $EX = 3.5$ ، ومن ثم يكون لدينا $E[g(X)] = \sqrt{3.5} = 1.871$ ، وبالتالي يُختم المثال بالنتيجة الآتية:

$$g[E(X)] > E[g(X)]$$

من العلاقات الشهيرة بين العزوم الابتدائية والعزوم الارتباطية لمتغيرين عشوائيين ما يُعرف باسم متباينة كوشي-شفارتز التي تقدّمها المبرهنة الآتية (سنقبلها دون برهان).

(٨, ١, ٢, ٧) مبرهنة (متباينة كوشي-شفارتز (Cauchy – Schwartz inequality))

ليكن X و Y متغيرين عشوائيين فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ بحيث إن $EX^2 < +\infty$ وكذلك $EY^2 < +\infty$ ، فعندئذ تكون المتباينة الآتية محققة من أجلهما:

$$[E(XY)]^2 \leq EX^2 \cdot EY^2 \quad [7,11]$$

وهذه المتباينة تعرف باسم متباينة كوشي-شفارتز (كارل هيرمان أمادوس شفارتز فيلسوف ورياضياتي ألماني Karl Hermann Amandus Schwarz (1843-1921))، وتعدّ هذه العلاقة من العلاقات المهمة في مجالات عديدة من الرياضيات (الاحتمالات، التحليل، الجبر و...).

(٩, ١, ٢, ٧) مثال:

ليكن $[\Omega, \mathcal{A}, P]$ الفضاء الاحتمالي الموافق لتجربة إلقاء حجر نرد متوازن لمرة واحدة فقط، ولنفترض أن X و Y متغيران عشوائيان مستقلان فوق $[\Omega, \mathcal{A}, P]$ ، ومُعَرَّفان من خلال العلاقتين $X(\omega) = \omega$ و $Y(\omega) = \omega^2$ ، فنجد أن مجموعة قيم كلٍّ من المتغيرين العشوائيين X و Y على الترتيب هما $X = \{1, 2, 3, 4, 5, 6\}$ و $Y = \{1, 4, 9, 16, 25, 36\}$ ، ولكن وجدنا سابقاً (في المثال ١ / من (٤, ١, ٢, ٧)) أن $EX = 3.5$ و $EX^2 = 15.1667$ ، وكذلك لدينا:

$$EY = \sum_{j \in J} y_j \cdot P(Y = y_j) = \sum_{\ell=1}^6 \ell \cdot P(X = \ell) = \sum_{\ell=1}^6 \ell \frac{1}{6} = \frac{1}{6} \sum_{\ell=1}^6 \ell = \frac{91}{6} = 15.167$$

ومن أجل العزم الابتدائي من المرتبة الثانية نجد:

$$EY^2 = \sum_{j \in J} y_j^2 \cdot P(Y = y_j) = \sum_{\ell=1}^6 \ell^2 \cdot P(X = \ell) = \frac{1}{6} \sum_{\ell=1}^6 \ell^2 = \frac{2275}{6} = 379.167$$

ومن ثم يكون لدينا $EX^2 \cdot EY^2 = 5750.826$ ، ومن جهة أخرى يمكننا أن نكتب بسبب الاستقلال بين X و Y ما يلي:

$$\begin{aligned} E(XY) &= \sum_{i \in I, j \in J} (x_i \cdot y_j) \cdot P(X = x_i, Y = y_j) = \sum_{i \in I, j \in J} x_i \cdot y_j \cdot P(X = x_i) \cdot P(Y = y_j) \\ &= \sum_{i \in I} x_i \cdot P(X = x_i) \sum_{j \in J} y_j P(Y = y_j) = E(X) \cdot E(Y) = 53.0845 \end{aligned}$$

ومن ثم يكون لدينا:

$$2817.964 = [E(X \cdot Y)]^2 < EX^2 \cdot EY^2 = 5750.826$$

وهذه النتيجة متوافقة مع متباينة كوشي - شفارتز.

الآن، وقبل تقديم بعض الخصائص للعزوم الابتدائية سنقوم بتقديم مفهوم مهم يندرج فيه متغيرين عشوائيين بأن واحد.

(١٠، ١، ٢، ٧) تعريف (التغاير - أو تمام التباين - لمتغيرين عشوائيين)

ليكن X و Y متغيرين عشوائيين فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ بحيث إن $E|X| < +\infty$ و $E|Y| < +\infty$ ، فعندئذ تدعى القيمة العددية $E[(X - EX) \cdot (Y - EY)]$ بـ **التغاير (أو تمام تباين)** Covariance لـ X و Y ، ويرمز له بـ $\text{cov}(X, Y)$. أي إن:

$$\text{cov}(X, Y) = E[(X - EX) \cdot (Y - EY)] \quad [7, 12]$$

(١١، ١، ٢، ٧) أمثلة

١- ليكن $[\Omega, \mathcal{A}, P]$ الفضاء الاحتمالي الموافق لتجربة إلقاء حجر نرد متوازن لمرة واحدة فقط، وليكن X و Y متغيرين عشوائيين فوق $[\Omega, \mathcal{A}, P]$ ومُعرَّفين من خلال العلاقتين $X(\omega) = \omega$ و $Y(\omega) = 3\omega$ ، فنجد أن مجموعة القيم لكل من المتغيرين العشوائيين X و Y على الترتيب هما $X = \{1, 2, 3, 4, 5, 6\}$ و $Y = \{3, 6, 9, 12, 15, 18\}$ ، ولنفترض أن قانون التوزيع المشترك لـ X و Y معطى كما في الجدول الآتي:

الجدول (١، ٧)

i	1	2	3	4	5	6	sum
X_i قيم X	1	2	3	4	5	6	
Y_i قيم Y	3	6	9	12	15	18	
$P(X = x_i, Y = y_i)$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	1

وبناء على هذه المعطيات يجب أن يكون:

$$P(X = x_i, Y = y_j) = 0 \quad ; i, j \in \mathbb{N}_6 \text{ with } i \neq j$$

وبحساب EX نجد أن $EX = 3.5$ ، وكذلك:

$$EY = \sum_{j \in J} y_j \cdot P(Y = y_j) = \sum_{\ell=1}^6 \ell \cdot P(Y = \ell) = \sum_{\ell=1}^6 \ell \cdot \frac{1}{6} = \frac{1}{6} \sum_{\ell=1}^6 \ell = \frac{63}{6} = 10.5$$

ومن ثم يكون لدينا تغاير X و Y يساوي:

$$\begin{aligned} \text{cov}(X, Y) &= E[(X - EX)(Y - EY)] = \sum_{i \in I, j \in J} (x_i - 3.5)(y_j - 10.5)P(X = x_i, Y = y_j) \\ &= \frac{1}{6} \sum_{k=1}^6 (k - 3.5)(3k - 10.5) = \frac{(18.75) + (6.75) + (0.75) + (0.75) + (6.75) + (18.75)}{6} = 8.75 \end{aligned}$$

وبهذا ينتهي حل هذا المثال.

٢- بالعودة إلى المثال (٩، ١، ٢، ٧) نجد ما يلي:

$$\mathbf{E}[(X - \mathbf{E} X)(Y - \mathbf{E} Y)] = \sum_{i \in I, j \in J} [(x_i - 3.5)(y_j - 15.167)] \cdot P(X = x_i, Y = y_j)$$

والآن، وبسبب الاستقلال بين X و Y يكون كل من $X - \mathbf{E} X$ و $Y - \mathbf{E} Y$ مستقلين أيضاً، ولذلك يمكننا أن نكتب الآتي:

$$\begin{aligned} \text{cov}(X, Y) &= \mathbf{E}[(X - \mathbf{E} X)(Y - \mathbf{E} Y)] = \sum_{i \in I, j \in J} [(x_i - 3.5)(y_j - 15.167)] \cdot P(X = x_i) P(Y = y_j) \\ &= \sum_{i \in I} (x_i - 3.5) \cdot P(X = x_i) \sum_{j \in J} (y_j - 15.167) \cdot P(Y = y_j) = 0 \end{aligned}$$

وهكذا ينتج لدينا:

$$\text{cov}(X, Y) = \mathbf{E}[(X - \mathbf{E} X)(Y - \mathbf{E} Y)] = 0$$

وهنا يجب الانتباه إلى أن $\mathbf{E}(Y - \mathbf{E} Y) = 0$ وأية قيمة مختلفة عن الصفر (قد تظهر في حساب $\mathbf{E}(Y - \mathbf{E} Y)$) تكون ناتجة عن عملية تدوير الأرقام في حساب $\mathbf{E} Y$.

نقدم فيما يلي بعض خصائص التوقع الرياضي للمتغير عشوائي، علماً أنه إذا أردنا إثبات صحة بعض هذه الخصائص فإننا سنفترض أن X و Y متغيرين عشوائيين متقطعين وذلك على سبيل التوضيح والتبسيط، وأما من أجل X و Y متغيرين عشوائيين مستمرين فإن هذه الخصائص تبرهن بطريقة مماثلة ولكن باستخدام التكاملات عوضاً عن المجاميع.

(١٢، ١، ٢، ٧) مبرهنة

ليكن X و Y متغيرين عشوائيين فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، وكل منهما يملك عزماً ابتدائياً من المرتبة الأولى (التوقع الرياضي لـ X و Y موجود)، فعندئذ إذا كان من أجل $-\infty < a \leq b < +\infty$ لدينا $a \leq X \leq b$ ، فإنه سيكون:

$$a \leq \mathbf{E} X \leq b \quad [7,13]$$

البرهان: بما أن $a \leq X \leq b$ و X يملك توقعاً رياضياً فإنه يمكننا أن نكتب الآتي:

$$a = a \underbrace{\sum_{i \in I} P(X = x_i)}_{=1} = \sum_{i \in I} a \cdot P(X = x_i) \leq \underbrace{\sum_{i \in I; a \leq x_i \leq b} x_i \cdot P(X = x_i)}_{\mathbf{E} X}$$

ولكن لدينا:

$$\mathbf{E} X = \sum_{i \in I; a \leq x_i \leq b} x_i \cdot P(X = x_i) \leq \sum_{i \in I} b \cdot P(X = x_i) = b \underbrace{\sum_{i \in I} P(X = x_i)}_{=1} = b$$

أي إن $a \leq \mathbf{E} X \leq b$ ، وبهذا يتم الإثبات.

(١٣، ١، ٢، ٧) نتائج

من المبرهنة السابقة نستنتج ما يلي:

١- من أجل $a = b$ يصبح لدينا $\mathbf{E} X = \mathbf{E} b = b$.

٢- من أجل $a = 0$ يصبح $0 \leq X$ ، ونتيجة للخاصية السابقة ينتج لدينا أنه إذا كان X متغيراً عشوائياً غير سالب فإنه سيكون لدينا $0 \leq \mathbf{E} X$.

(١٤, ١, ٢, ٧) مبرهنة

ليكن X و Y متغيرين عشوائيين فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، وكل منهما يملك عزماً ابتدائياً من المرتبة الأولى، فإذا كان $a, b \in \mathbb{R}$ ثوابت مع $a \neq 0$ ، فإن العلاقة الآتية ستكون مُحَقَّقة:

$$\mathbf{E}(aX + bY) = a \cdot \mathbf{E}X + b \cdot \mathbf{E}Y \quad [6,14-a]$$

البرهان: بما أن كل من X و Y يملك توقُّعاً رياضياتياً، فعندئذ يمكننا أن نكتب الآتي:

$$\begin{aligned} \mathbf{E}(aX + bY) &= \sum_{i \in I, j \in J} (a \cdot x_i + b \cdot y_j) P(X + Y = x_i + y_j) \\ &= \sum_{i \in I, j \in J} [a \cdot x_i \cdot P(X + Y = x_i + y_j | Y = y_j) + b \cdot y_j \cdot P(X + Y = x_i + y_j | X = x_i)] \\ &= a \sum_{i \in I} x_i P(X + y_j = x_i + y_j) + b \sum_{j \in J} y_j \cdot P(x_i + Y = x_i + y_j) \\ &= a \sum_{i \in I} x_i P(X = x_i) + b \sum_{j \in J} y_j P(Y = y_j) = a \mathbf{E}X + b \mathbf{E}Y \end{aligned}$$

علماً أن الاحتمال الشرطي لـ $X = x_i$ علماً أن $Y = y_j$ مع $0 < P(Y = y_j)$ مُحَقَّقاً يجب أن يفهم على النحو الآتي:

$$P(X = x_i | Y = y_j) = \frac{P(\{\omega \in \Omega ; X(\omega) = x_i\} \cap \{\omega \in \Omega ; Y(\omega) = y_j\})}{P(\{\omega \in \Omega ; Y(\omega) = y_j\})}$$

وبهذا يتم البرهان.

(١٥, ١, ٢, ٧) نتائج

من هذه المبرهنة يتضح لنا أن التوقع الرياضي هو مؤثر خطي، وعلاوة على ذلك ينتج:

١- من أجل الحالة الخاصة $P(Y = 1) = 1$ سيكون لدينا:

$$\mathbf{E}(aX + b) = a \cdot \mathbf{E}X + b \quad [7,14-b]$$

٢- من أجل الحالة الخاصة $a = 1$ و $\mathbf{E}X = b$ سيكون لدينا:

$$\mathbf{E}(X - \mathbf{E}X) = 0 \quad [7,14-c]$$

علماً أن المتغير العشوائي $X - \mathbf{E}X$ يُدعى **متغيراً عشوائياً مركزياً**، ومن ثم يكون التوقع الرياضي لمتغير عشوائي مركزي يساوي الصفر دوماً (وقد لاحظنا هذا في أمثلة سابقة).

(١٦, ١, ٢, ٧) مبرهنة

ليكن X و Y متغيرين عشوائيين فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، وكل منهما يملك عزماً ابتدائياً من المرتبة الأولى، فعندئذ يكون لدينا:

$$\mathbf{E}(X \cdot Y) = \mathbf{E}X \cdot \mathbf{E}Y - \text{cov}(X, Y) \quad [7,15-a]$$

البرهان: بما أن كلا من X و Y يملك توقُّعاً رياضياتياً، فعندئذ بملاحظة أن:

$$XY = \mathbf{E}X \cdot \mathbf{E}Y + (X - \mathbf{E}X) \mathbf{E}Y + (Y - \mathbf{E}Y) \mathbf{E}X + (X - \mathbf{E}X) \cdot (Y - \mathbf{E}Y)$$

وباستخدام المبرهنتين السابقتين ونتائجها نتج لدينا العلاقة الآتية التي تثبت صحة العلاقة [7,15-a]:

$$\mathbf{E}(XY) = \mathbf{E}X \cdot \mathbf{E}Y + \mathbf{E}[(X - \mathbf{E}X)(Y - \mathbf{E}Y)] = \mathbf{E}X \cdot \mathbf{E}Y + \text{cov}(XY)$$

(٧, ٢, ١, ١٧) مبرهنة

ليكن X و Y متغيرين عشوائيين فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، وكل منهما يملك عزمًا ابتدائيًا من المرتبة الأولى على الأقل، فإذا كانا مستقلين بعضهما عن بعض، فعندئذ يكون لدينا $\text{cov}(X, Y) = 0$.

البرهان: بسبب استقلال المتغيرين العشوائيين X و Y ، وباستخدام خصائص التوقع الرياضي السابقة، والأخذ بالحسبان خصائص المتسلسلات العددية المتقاربة (لأنه من الممكن أن تكون المجاميع غير منتهية)، فإنه يمكننا كتابة الآتي:

$$\begin{aligned}\text{cov}(X, Y) &= \mathbf{E}[(X - \mathbf{E}X) \cdot (Y - \mathbf{E}Y)] = \sum_{i \in I, j \in J} (x_i - \mathbf{E}X) \cdot (y_j - \mathbf{E}Y) P(X = x_i, Y = y_j) \\ &= \sum_{i \in I, j \in J} (x_i - \mathbf{E}X) \cdot (y_j - \mathbf{E}Y) P(X = x_i) P(Y = y_j) = \text{RHS}\end{aligned}$$

ولكن لدينا:

$$\begin{aligned}\text{RHS} &= \sum_{i \in I} (x_i - \mathbf{E}X) P(X = x_i) \cdot \sum_{j \in J} (y_j - \mathbf{E}Y) P(Y = y_j) \\ &= [\mathbf{E}(X - \mathbf{E}X)] \cdot [\mathbf{E}(Y - \mathbf{E}Y)] = [\mathbf{E}X - \mathbf{E}(\mathbf{E}X)] \cdot [\mathbf{E}Y - \mathbf{E}(\mathbf{E}Y)] \\ &= [\mathbf{E}X - \mathbf{E}X] \cdot [\mathbf{E}Y - \mathbf{E}Y] = 0\end{aligned}$$

ومن ثم ينتج لدينا أن $\text{cov}(X, Y) = 0$ وبهذا يتم البرهان.

(٧, ٢, ١, ١٨) ملاحظات

١- إن عكس المبرهنة السابقة غير صحيح في الحالة العامة، والمثال الآتي (٧, ٢, ١, ١٩) يوضح لنا ذلك.

٢- إذا كان كل من X و Y يملك توقعًا رياضيًا، وكان $\text{cov}(X, Y) = 0$ ، فعندئذ يقال إن المتغيرين العشوائيين X و Y غير مرتبطين **Uncorrelated**، وهكذا ينتج لدينا من الملاحظة السابقة أنه إذا كان X و Y غير مرتبطين فإن ذلك لا يعني أنها مستقلان. أي إنه إذا كان $\mathbf{E}(XY) = \mathbf{E}X \cdot \mathbf{E}Y$ فإن ذلك لا يعني أن المتغيرين العشوائيين X و Y مستقلين.

(٧, ٢, ١, ١٩) مثال

ليكن X و Y متغيرين عشوائيين بسيطين فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ وبمجموعتي قيم $X = \{-1, 2\}$ و $Y = \{-2, -1, 1, 2\}$ على الترتيب، ويحققان البندين الآتيتين:

$$\text{a) } P(X = -1, Y = +1) = P(X = -1, Y = -1) = \frac{1}{3}$$

$$\text{b) } P(X = 2, Y = 2) = P(X = 2, Y = -2) = \frac{1}{6}$$

لاحظ أن باقي الاحتمالات الممكنة لـ X و Y معًا تساوي الصفر، وعلاوة على ذلك نجد ما يلي:

$$P(X = 2) = P(X = 2, Y = 2) + P(X = 2, Y = -2) = \frac{1}{6} + \frac{1}{6} = \frac{1}{3}$$

$$P(Y = 2) = P(X = 2, Y = 2) = \frac{1}{6}$$

$$\frac{1}{6} = P(X = 2, Y = 2) \neq P(X = 2) \cdot P(Y = 2) = \frac{1}{18}$$

أي إن X و Y ليسا مستقلين، وعلى الرغم من ذلك لدينا:

$$EX = \sum_{\substack{x=2, x=-1 \\ y=2, y=-2 \\ y=1, y=-1}} x P(X=x) = 2 \left(\frac{1}{6} + \frac{1}{6} \right) + (-1) \left(\frac{1}{3} + \frac{1}{3} \right) = 0$$

وبالمثل نجد $EY = 0$ أيضاً، ومن ثمَّ يصبح لدينا أنَّ $\text{cov}(X, Y) = E(XY)$ ، ولكن لدينا:

$$E(XY) = \sum_{\substack{x=2, x=-1 \\ y=2, y=-2 \\ y=1, y=-1}} (x \cdot y) P(X=x, Y=y) = 4 \left(\frac{1}{6} \right) - 4 \left(\frac{1}{6} \right) + 1 \left(\frac{1}{3} \right) - 1 \left(\frac{1}{3} \right) = 0$$

ومنه ينتج لدينا أنَّ $\text{cov}(X, Y) = 0$ ، وهكذا أمكننا إيجاد متغيرين عشوائيين X و Y غير مستقلين وتغايرهما معدوماً.

(٧, ٢, ١, ٢٠) ملاحظات

١- في الحالة الخاصة عندما يكون متغيران عشوائيان X و Y مستقلين، فإنه يصبح للعلاقة [7,15-a] العرض الآتي:

$$E(XY) = EX \cdot EY \quad [7,15-b]$$

وذلك لأنه بسبب استقلال X عن Y ، وباستخدام خصائص المتسلسلات العددية المقاربة يمكننا أن نكتب الآتي:

$$\begin{aligned} E(XY) &= \sum_{i \in I, j \in J} (x_i \cdot y_j) P(X=x_i, Y=y_j) = \sum_{i \in I, j \in J} (x_i \cdot y_j) \cdot P(X=x_i) \cdot P(Y=y_j) \\ &= \sum_{i \in I} x_i P(X=x_i) \cdot \sum_{j \in J} y_j P(Y=y_j) = EX \cdot EY \end{aligned}$$

نشير هنا إلى أنَّ هذه النتيجة غير قابلة للعكس، أي إنه إذا كانت العلاقة [7,15-b] مُحَقَّقة من أجل متغيرين عشوائيين X و Y فإنَّ ذلك لا يعني بالضرورة أنَّهما مستقلان بعضهما عن بعض، والمثال السابق (٧, ٢, ١, ٩) وضح لنا ذلك، حيث كان X و Y متغيرين عشوائيين غير مستقلين ومع ذلك كانت العلاقة [7,15-b] مُحَقَّقة.

٢- إنَّ المقدار $E(XY)$ يدعى **العزم الارتباطي** بين X و Y .

٣- بالرجوع إلى المثال (٧, ٢, ١, ٩) حيث كان لدينا متغيرين عشوائيين X و Y يملكان توقعاً رياضياً مع $EX = 3.5$ ، و $EY = 10.5$ ، فإننا نجد:

$$E \frac{X}{Y} = \sum_{i \in I, j \in J} \frac{x_i}{y_j} \cdot P(X=x_i, Y=y_j) = \frac{1}{6} \sum_{k=1}^6 \frac{k}{3k} = \frac{1}{6} \sum_{k=1}^6 \frac{1}{3} = \frac{1}{3}$$

ومنه يكون:

$$\frac{1}{3} = E \frac{X}{Y} = \frac{EX}{EY} = \frac{3.5}{10.5} = \frac{1}{3}$$

أي إنه من أجل ذلك المثال لدينا $E \frac{X}{Y} = \frac{EX}{EY}$ ، ولكن **يجب الانتباه** إلى أنه إذا كانا متغيرين عشوائيين X و Y يملكان توقعاً رياضياً، وبفرض أنَّ $P(Y \neq 0) = 1$ (ومن ثمَّ $EY \neq 0$) فعندئذ وجود هذا التوقع الرياضي لكل من X و Y لا يعني بالضرورة وجود التوقع الرياضي لـ $\frac{X}{Y}$ ، ومثال على ذلك إذا كان X_1 و X_2 متغيرين عشوائيين مستقلين، وكان لـ X_1 توزيع طبيعي $N(0,1)$ ولـ X_2 توزيع كاي مربع $\chi^2(1)$ ، فإنَّ كل منهما يملك توقعاً رياضياً حيث لدينا $EX_1 = 0$ و $EX_2 = 1$ (من أجل الاطلاع على قيم

التوقعات الرياضية للمتغيرات العشوائية الشهيرة التي سنوردها هنا ولاحقاً نجدها في جدول التوزيعات الاحتمالية الشهيرة في آخر هذا الكتاب)، فلو أخذنا $Y := \sqrt{X_2}$ ، فعندئذ يُرهن على أن للمتغير العشوائي $Z = \frac{X_1}{Y}$ توزيع كوشي $C(0,1)$ (انظر [65])، وهذا التوزيع لا يملك عزوماً ابتدائية ولا من أية مرتبة كما بينا ذلك سابقاً.

وأكثر من ذلك حتى في حال وجود $\frac{EX}{Y}$ فإنه ليس بالضرورة أن يكون $\frac{EX}{Y}$ يساوي $\frac{EX}{EY}$ ، وذلك لأنه في الحالة العامة لدينا (انظر الملاحظ التالية) $\frac{EX}{Y} \neq \frac{EX}{EY}$ ، فلو أخذنا على سبيل المثال X و Y متغيرين عشوائيين مستقلين بحيث إن $X \sim \chi^2(n)$ مع $3 \leq n$ و $Y \sim \chi^2(m)$ فيكون توقعهما الرياضيائي $EX = n$ و $EY = m$ على الترتيب، علماً أن n و m أعداد صحيحة موجبة، فلو أخذنا الآن $Z = \frac{X/n}{Y/m} = \frac{mX}{nY}$ فعندئذ يكون للمتغير العشوائي Z توزيع فيشر $F(m;n)$ حيث لدينا $EZ = \frac{n}{n-2}$ (انظر [65])، في حين أن:

$$\frac{E(mX)}{E(nY)} = \frac{m \cdot EX}{n \cdot EY} = \frac{m \cdot n}{n \cdot m} = 1 \neq \frac{n}{n-2} \quad \text{for } n \geq 3$$

٤- إذا كان كل من X و Y يملك توقعاً رياضياتياً، وبفرض أن $P(Y \neq 0) = 1$ ، وأن $g: \mathbb{R} \times \mathbb{R} \rightarrow \mathbb{R}$ دالة قيوسة بالنسبة إلى $\mathbb{R} \times \mathbb{R}$ و $\mathbb{R} \times \mathbb{R}$ ، فعندئذ الصيغة التقريبية لحساب التوقع الرياضيائي لـ $g(X, Y)$ تُعطى بالعلاقة الآتية:

$$\begin{aligned} E[g(X, Y)] &\approx g(EX, EY) + \frac{1}{2} \text{var} X \frac{\partial^2}{\partial x^2} g(x, y) \Big|_{x=EX, y=EY} \\ &+ \frac{1}{2} \text{var} Y \frac{\partial^2}{\partial y^2} g(x, y) \Big|_{x=EX, y=EY} \\ &+ \text{cov}(X, Y) \frac{\partial^2}{\partial x \partial y} g(x, y) \Big|_{x=EX, y=EY} \end{aligned}$$

التي ينتج عنها أنه في حال أن $P(Y \neq 0) = 1$ فإنه يكون لدينا:

$$E \frac{X}{Y} \approx \frac{EX}{EY} - \frac{1}{(EY)^2} \text{cov}(X, Y) + \frac{EX}{(EY)^3} \text{var} Y \quad [7,16]$$

٥- من أجل أي متغير عشوائي غير سالب X فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ توجد متتالية متزايدة $(X_n)_{n \in \mathbb{N}}$ من المتغيرات العشوائية البسيطة فوق $[\Omega, \mathcal{A}, P]$ بحيث إنه من أجل كل $\omega \in \Omega$ تكون العلاقة $X(\omega) = \lim_{n \rightarrow \infty} X_n(\omega)$ مُحَقَّقة، وحينئذ يُحسب التوقع الرياضيائي لـ X من خلال العلاقة الآتية:

$$EX = \lim_{n \rightarrow \infty} EX_n \quad [7,17]$$

٦- من المعلوم أن كل متغير عشوائي كفي X فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ يمكن كتابته على شكل فرق متغيرين عشوائيين غير سالبين من خلال العلاقة $X = X^+ - X^-$ ، علماً أنه من أجل كل $\omega \in \Omega$ لدينا:

$$X^+(\omega) := \max \{X(\omega), 0\} \quad \& \quad X^-(\omega) := -\min \{X(\omega), 0\}$$

فإذا كان $EX^+ < +\infty$ أو $EX^- < +\infty$ ، فعندئذ يكون التوقع الرياضيائي لـ X مُعرِّفاً ويُعطى بالعلاقة الآتية:

$$EX = EX^+ - EX^- \quad [7,18]$$

ولكي يملك متغير عشوائي كفي X توقعاً رياضياً يجب أن يملك كل من X^+ و X^- توقعاً رياضياً أيضاً (أي إن $E X^+ < +\infty$ و $E X^- < +\infty$)، وحينئذ يُحسب التوقع الرياضي لـ X بالعلاقة [7,17]، ويكون لدينا:

$$EX = EX^+ - EX^- < +\infty$$

توضح لنا المبرهنة الآتية إحدى الطرائق التي تساعدنا في تقدير قيمة التوقع الرياضي لمتغير عشوائي غير سالب.

(٧, ٢, ١, ٢١) مبرهنة (متباينة ماركوف Markov inequality)

إذا كان X متغيراً عشوائياً غير سالب ويملك توقعاً رياضياً، فعندئذ من أجل كل $0 < \varepsilon$ (عدد حقيقي يمكن جعله صغيراً بالقدر الذي نريد) تكون المتباينة الآتية مُحَقَّقة:

$$EX \geq \varepsilon \cdot P(X \geq \varepsilon) \quad [7,19-a]$$

وهذه المتباينة تُدعى **متباينة ماركوف** نسبةً إلى الرياضي الروسي **ماركوف** (Andrey Andreyevich Markov (1856-1922).

البرهان: على سبيل التبسيط سنثبت صحة هذه المتباينة من أجل متغير عشوائي متقطع. لذلك سنأخذ $0 < \varepsilon$ ، فعندئذ يمكننا أن نكتب الآتي:

$$\begin{aligned} EX &= \sum_{i \in I} x_i P(X = x_i) = \sum_{i \in I, x_i < \varepsilon} x_i P(X = x_i) + \sum_{i \in I, x_i \geq \varepsilon} x_i \cdot P(X = x_i) \\ &\geq \sum_{i \in I, x_i \geq \varepsilon} x_i P(X = x_i) \geq \varepsilon \sum_{i \in I, x_i \geq \varepsilon} P(X = x_i) = \varepsilon \cdot P(X \geq \varepsilon) \end{aligned}$$

وبهذا يتم البرهان.

(٧, ٢, ١, ٢٢) ملاحظة

إن المتباينة السابقة [7,19-a] تكافئ المتباينة الآتية:

$$F_X(\varepsilon) \geq 1 - \frac{EX}{\varepsilon} \quad [7,19-b]$$

التي تُمكننا من تقدير قيمة دالة التوزيع الاحتمالية لمتغير عشوائي غير سالب X لدى معرفة قيمته المتوقعة، أو تقدير التوقع الرياضي لمتغير عشوائي غير سالب X لدى معرفة دالة توزيعه الاحتمالية.

تقدم لنا المبرهنة الآتية إحدى المتباينات المهمة في مجالي العشوائيات والرياضيات التي تعود إلى الرياضي الروسي **ليابانوف** (Aleksandr Mikhailovich Lyapunov (1857-1918).

(٧, ٢, ١, ٢٣) مبرهنة (متباينة ليابانوف Lyapunov Inequality)

إذا كان X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، ويملك توقعاً رياضياً حتى المرتبة n ، فعندئذ من أجل أية قيم $\ell > k$ تكون المتباينة الآتية (وتعرف باسم متباينة ليابانوف) مُحَقَّقة:

$$\left(E |X|^k \right)^{\frac{1}{k}} \leq \left(E |X|^\ell \right)^{\frac{1}{\ell}} \quad [7,20]$$

البرهان: لنضع $m = \frac{\ell}{k}$ فيكون لدينا $1 < m$ ، ولنأخذ $Y = |X|^k$ ، فعندئذ بتطبيق متباينة جينسين على المتغير العشوائي $g(Y) = |Y|^m = (|X|^k)^m = |X|^\ell$ ، فنحصل على المتباينة $E |X|^\ell \geq (E |X|^k)^m$ ، ومن هذه المتباينة ينتج لدينا أن:

$$\left(\mathbb{E} |X|^k \right)^{\frac{1}{k}} \leq \mathbb{E} |X|^\ell$$

وبأخذ الجذر من المرتبة ℓ لطرفي المتباينة السابقة نحصل على المتباينة الآتية:

$$\left(\mathbb{E} |X|^k \right)^{\frac{1}{k}} \leq \left(\mathbb{E} |X|^\ell \right)^{\frac{1}{\ell}}$$

وبهذا يتم البرهان.

(٧, ٢, ١, ٢) نتيجة

تحت فرضيات المبرهنة السابقة نجد أن:

$$\mathbb{E} |X| \leq \left(\mathbb{E} |X|^2 \right)^{\frac{1}{2}} \leq \left(\mathbb{E} |X|^3 \right)^{\frac{1}{3}} \leq \dots \leq \left(\mathbb{E} |X|^n \right)^{\frac{1}{n}}$$

والتي ينتج عنها أنه من أجل $n > k$ عدد صحيح سيكون لدينا ما يلي:

$$\mathbb{E} |X|^k \leq \left(\mathbb{E} |X|^n \right)^{\frac{k}{n}} \leq \mathbb{E} |X|^k$$

(٧, ٢, ٢) العزوم المركزية لمتغير عشوائي **Centered Moments of Random Variables**

من التطبيقات المهمة للتوقع الرياضي لدالة قیوسة g ما يعرف باسم **العزوم حول نقطة** c من R لمتغير عشوائي التي سنبدأها بالتعريف الآتي.

(٧, ٢, ٢, ١) تعريف (العزم والعزم المطلق لمتغير عشوائي حول نقطة)

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، و $2 \leq k$ عدداً صحيحاً، و $c \in R$ كيفياً ولكن مشتباً، فعندئذٍ يسمي المقدار:

$$\text{a) } \sigma_X^{(k)}(c) := \mathbb{E} (X - c)^k \quad [7,21-a]$$

العزم حول c من المرتبة k للمتغير العشوائي X ،

$$\text{b) } \beta_X^{(k)}(c) := \mathbb{E} |X - c|^k \quad [7,21-b]$$

العزم المطلق حول c من المرتبة k للمتغير العشوائي X .

الآن، يقال إن متغيراً عشوائياً X يملك عزماً حول c من المرتبة k إذا كان $\mathbb{E} |X - c|^k < +\infty$ ، أي إذا كان العزم المطلق حول c من المرتبة k للمتغير العشوائي X موجوداً.

(٧, ٢, ٢, ٢) ملاحظات

١- في حال عدم وجود التباين (كأن تكون الدراسة متعلقة بمتغير عشوائي واحد X) سنكتب (على سبيل التبسيط) $\sigma^{(k)}(c)$ بدلاً من $\sigma_X^{(k)}(c)$ ، وكذلك $\beta^{(k)}(c)$ عوضاً عن $\beta_X^{(k)}(c)$.

٢- في الحالة الخاصة إذا كان $c = 0$ ، فعندئذٍ يصبح لدينا:

$$\sigma^{(k)}(0) = \mathbb{E} X^k = \mu^{(k)} \quad \& \quad \beta^{(k)}(0) = \mathbb{E} |X|^k$$

٣- في الحالة الخاصة عندما يكون $c = \mathbb{E} X$ ، فعندئذٍ سيكون $Y = X - \mathbb{E} X$ متغيراً عشوائياً مركزياً، ولذلك فإن:

$$\mathbb{E} Y^k = \mathbb{E} (X - \mathbb{E} X)^k$$

يُدعى **العزم المركزي من المرتبة k للمتغير العشوائي X** ، وبالمثل يُدعى $E|X - EX|^k$ **العزم المركزي المطلق من المرتبة k للمتغير العشوائي X** .

٤- على سبيل التبسيط (وما لم يُؤد ذلك إلى التباس) سنكتب $\sigma^{(k)}$ بدلاً عن $\sigma^{(k)}(EX)$ ، وكذلك $\beta^{(k)}$ بدلاً عن $\beta^{(k)}(EX)$ أي إنه لدينا:

$$\sigma^{(k)} := \sigma^{(k)}(EX) = E(X - EX)^k \quad [7,22-a]$$

$$\beta^{(k)} := \beta^{(k)}(EX) = E|X - EX|^k \quad [7,22-b]$$

وقياساً على ما سبق يُقال إنَّ متغيراً عشوائياً X يملك عزماً مركزياً من المرتبة k إذا كان العزم المركزي المطلق من المرتبة k للمتغير العشوائي X موجوداً، أي إذا كان $E|X - EX|^k < +\infty$.

٥- في الحالة الخاصة عندما يكون $k = 2$ فإنَّ العزم المركزي من المرتبة الثانية للمتغير العشوائي X يُدعى **"التباين"** للمتغير العشوائي X ، ويرمز له بـ $\text{var } X$ ، أي إنه لدينا:

$$\sigma^{(2)} = E(X - EX)^2 \triangleq \text{var } X \quad [7,23]$$

٦- إنَّ الجذر التربيعي الموجب لتباين المتغير العشوائي X يُدعى **الانحراف المعياري** للمتغير العشوائي X ، ويرمز له عادةً بـ σ_X ، وفي حال عدم وجود التباس (كأن تكون الدراسة متعلقة بمتغير عشوائي واحد فقط X) يرمز له بـ σ على سبيل التبسيط، أي إنَّ:

$$\sigma := +\sqrt{\text{var } X} \quad [7,24]$$

٧- من هذه العلاقة الأخيرة [7,24] ينتج لدينا $\sigma^2 = \text{var } X$ ، وبما أنَّ $\sigma^{(2)} = \text{var } X$ ، فلذلك يُكتب في هذه الحالة الخاصة فقط $\sigma^{(2)} = \sigma^2$ ، وهذا يشير بدوره إلى أنَّ التباين هو مقدار غير سالب، حيث يُكتب مباشرة (في الكثير من الكتب والمراجع) أنَّ:

$$\sigma^2 = \text{var } X = E(X - EX)^2 \quad [7,25]$$

٨- يجب الانتباه هنا إلى أنَّ $\sigma^{(k)} \neq \sigma^k$ في الحالة العامة؛ وذلك لأنَّ العزم المركزي σ^k $0 \leq \sigma^k$ دوماً في حين أنَّ المقدار $\sigma^{(k)}$ قد يكون سالباً من أجل القيم الفردية لـ k ، فعلى سبيل المثال لو أخذنا X متغيراً عشوائياً متقطعاً وأخذ جميع القيم الآتية بالاحتمال نفسه:

9 5 8 4 7 4 8 4 8 5 6 9 7

فعندئذ نجد أنَّ:

$$EX = \sum_{i=1}^{15} x_i \cdot P(X = x_i) = \frac{1}{15} \sum_{i=1}^{15} x_i = 6.4$$

وكذلك نجد أنَّ $\sigma^2 = 3.44$ ، ومنه يكون $\sigma = 1.855$ ، ومن ثمَّ ينتج لدينا $\sigma^5 = 21.948$ ، في حين أنَّ:

$$\sigma^{(5)} = \sum_{i=1}^{15} (x_i - EX)^5 \cdot P(X = x_i) = \frac{1}{15} \sum_{i=1}^{15} (x_i - EX)^5 = -3.303$$

حيث نلاحظ أنَّ $\sigma^{(5)} \neq \sigma^5$.

٩- يُنظر إلى قيمة $\sigma^2 = \text{var } X$ كمقياس لتبعثر قيم المتغير العشوائي X حول متوسط قيمه، ولكن يجب الانتباه إلى أنَّ القيمة الناتجة عنه تقرأ بالوحدة المربعة، ولذلك لا تستخدم في الجوانب التطبيقية، وإنَّما تستخدم قيمة الانحراف المعياري لـ X كمقياس لتبعثر قيم X حول متوسطها في الجوانب التطبيقية لأنَّ له وحدة القياس نفسها التي لقيم X .

١٠- يُرهن (سنبليها دون برهان) على أنه إذا كان متغير عشوائي X يملك عزمًا ابتدائيًا من المرتبة k مع $k \in \mathbb{N}$ و $2 \leq k$ ، فإنه ستكون العلاقة الآتية مُحَقَّقة:

$$\sigma^{(k)} = (-1)^{k-1} (k-1) \mu^k + \sum_{i=2}^k (-1)^{k-i} \binom{k}{i} \mu^{(i)} \mu^{k-i} \quad [7,26]$$

وهذه العلاقة تفيدنا بأن وجود العزم المركزي $\sigma^{(k)}$ لمتغير عشوائي ينتج من وجودية العزوم الابتدائية $\mu^{(\ell)}$ لكل القيم $1 \leq \ell \leq k$ أيضاً.

١١- إن تباین متغير عشوائي X يمكن أن يُحسب باستخدام العلاقة الآتية أيضاً:

$$\text{var } X = \mathbf{E} X^2 - (\mathbf{E} X)^2 = \mu^{(2)} - \mu^2 \quad [7,27]$$

وهي تعرف باسم **صيغة شتاينر** Steiner Formula (سميت كذلك لتمثيلها مع صيغة شتاينر-أو المبرهنة الأولى لهويغنز-في الميكانيكا).

سنقدم فيما يلي بعض خصائص التباين لمتغير عشوائي دون إثبات.

(٧, ٢, ٢, ٣) خصائص التباين للمتغيرات العشوائية

ليكن X و Y متغيرين عشوائيين فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، وسنفترض أن $\mathbf{E} X^2 < +\infty$ وكذلك $\mathbf{E} Y^2 < +\infty$ ، فعندئذ:

١- من أجل أي عدد حقيقي $c \in \mathbb{R}$ سيكون لدينا $\text{var } X \leq \sigma^{(2)}(c)$ ، وهذا يعني أن تباین متغير عشوائي يُعدُّ أصغرياً تحت عملية العزوم ذات المرتبة الثانية حول أي عدد $c \in \mathbb{R}$ ، وتكون إشارة المساواة في المتباينة السابقة مُحَقَّقة إذا كان $P(X=c)=1$ ، أي عندما يكون X خاضعاً للتوزيع وحيد النقطة في c فقط، ومن ثمَّ سيكون لدينا في هذه الحالة الخاصة (يترك برهانها تمريناً للقارئ):

$$\text{var } X = \sigma^{(2)}(c) = 0$$

٢- من أجل أي عددين a و $b \in \mathbb{R}$ مع $a \neq 0$ تكون العلاقة الآتية مُحَقَّقة:

$$\text{var}(aX + b) = a^2 \text{var } X \quad [7,28]$$

ومن هذه الخاصية ينتج ما يلي:

$$\text{a) } \text{var}(-X) = \text{var } X \quad \& \quad \text{b) } \text{var} \left(\frac{X}{\sqrt{\text{var } X}} \right) = 1 \quad \text{for } \text{var } X > 0$$

٣- من تعريف التباين نستنتج أن:

$$\text{var}(X + Y) = \text{var } X + \text{var } Y + 2 \cdot \text{cov}(X, Y) \quad [7,29-a]$$

وعندما يكون X و Y مستقلين فإنه سيكون $\text{cov}(X, Y) = 0$ ، ومن ثمَّ يصبح لدينا من أجل هذه الحالة الخاصة:

$$\text{var}(X + Y) = \text{var } X + \text{var } Y \quad [7,29-b]$$

٤- لدينا:

$$\begin{aligned} \text{var}(X \cdot Y) &= (\mathbf{E} Y)^2 \text{var } X + (\mathbf{E} X)^2 \text{var } Y + 2 \mathbf{E} X \cdot \mathbf{E} Y \cdot \text{cov}(X, Y) \\ &\quad - [\text{cov}(X, Y)]^2 + \mathbf{E}[(X - \mathbf{E} X)^2 \cdot (Y - \mathbf{E} Y)^2] \\ &\quad + 2 \mathbf{E} Y \cdot \mathbf{E}[(X - \mathbf{E} X)^2 \cdot (Y - \mathbf{E} Y)] + 2 \mathbf{E} X \cdot \mathbf{E}[(X - \mathbf{E} X) \cdot (Y - \mathbf{E} Y)^2] \end{aligned} \quad [7,30-a]$$

وفي حال كان X و Y مستقلاً عن بعضهما البعض فإنه ينتج لدينا:

$$\text{var}(X \cdot Y) = (EY)^2 \text{var} X + (EX)^2 \text{var} Y + \text{var} X \cdot \text{var} Y \quad [7,30-b]$$

٥- انطلاقاً من خواص التوقع الرياضي يتبين لنا أنه تحت الفرضيات الواردة آنفاً وبفرض أن $X \neq 0$ و $Y \neq 0$ باحتمال يساوي الواحد، فعندئذ ليس بالضرورة أن يكون $\text{var} \frac{X}{Y}$ موجوداً، وحتى في حال وجوده فقد يكون $\text{var} \frac{X}{Y} \neq \frac{\text{var} X}{\text{var} Y}$ ، ولكن الصيغة الآتية تُعطينا قيمة تقريبية لحساب $\text{var} \frac{X}{Y}$ في حال وجودها:

$$\text{var} \frac{X}{Y} \approx \left(\frac{EX}{EY} \right)^2 \cdot \left[\frac{\text{var} X}{(EX)^2} + \frac{\text{var} Y}{(EY)^2} + 2 \frac{\text{cov}(X, Y)}{EX \cdot EY} \right] \quad [7,31-a]$$

في الحقيقة إن الصيغة السابقة تنتج عن صيغة أكثر عمومية لها العرض التالي:

$$\begin{aligned} \text{var}(g(X, Y)) &\approx \text{var} X \left[\frac{\partial}{\partial x} g(x, y) \Big|_{EX, EY} \right]^2 + \text{var} Y \left[\frac{\partial}{\partial y} g(x, y) \Big|_{EX, EY} \right]^2 \\ &+ 2 \text{cov}(X, Y) \left[\frac{\partial}{\partial x} g(x, y) \Big|_{EX, EY} \frac{\partial}{\partial y} g(x, y) \Big|_{EX, EY} \right] \end{aligned} \quad [7,31-b]$$

علماً أن g دالة معرفة على \mathbb{R}^2 وقيوسة بالنسبة إلى \mathbb{R}^2 .

(٤, ٢, ٧) ملاحظات

١- تجدر الإشارة هنا إلى أن كل متغير عشوائي تباينه يساوي الواحد يُدعى متغيراً عشوائياً **مُستَظهِراً** Normalized random variable، ولذلك فإن عملية الانتقال من متغير عشوائي X إلى متغير عشوائي Y مُعطى من خلال العلاقة الآتية:

$$Y = \frac{X}{\sqrt{\text{var} X}} \quad \text{for } \text{var} X > 0 \quad [7,32]$$

تُدعى عملية **استنظام** Normalization للمتغير العشوائي X .

٢- إذا كان لمتغير عشوائي X توقع رياضي معدوم وتباين يساوي الواحد فعندئذ يُدعى X متغيراً عشوائياً **معياريّاً** (وقياسيّاً) Standard random variable، ومن ثم فإن عملية تحويل متغير عشوائي X إلى متغير عشوائي مُعطى بالعلاقة الآتية:

$$Z = \frac{X - EX}{\sqrt{\text{var} X}} \quad \text{for } \text{var} X > 0 \quad [7,33]$$

تُدعى عملية **استقياس** (أو استقياس) Standardization للمتغير العشوائي X .

قد نكون في بعض الأحيان بحاجة إلى حساب قيمة العزوم الابتدائية (ومن ثم التباين أيضاً) لمتغير عشوائي X ، ووفقاً لما سبق قد يكون من غير الممكن في متابعة تنفيذ العمليات الحسابية لدى مرحلة من مراحل الحساب (حيث يكون استخدام الصيغ السابقة صعب جداً إن لم يكن غير ذي جدوى. انظر المثال / ٢ / من الأمثلة القادمة (٤, ٢, ٧)). لذلك طوّرت طريقة أخرى لحساب العزوم بحيث تساعد على تجاوز تلك الصعوبات في الحساب. هذه الطريقة عُرِفَت باسم **العزوم العامليّة**، وتقدمها لنا الفقرة التالية.

(٣, ٢, ٧) العزوم العامليّة (أو الضربّي) لمتغير عشوائي Factorial Moments of Random Variables

كما أوضحنا أعلاه فإن للعزوم العامليّة دوراً فعالاً في حساب العزوم الابتدائية لمتغيرات عشوائية، والتعريف الآتي يقدم لنا هذا المفهوم.

(١, ٣, ٢, ٧) تعريف (العزم العاملي (أو الضربي) لمتغير عشوائي)

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، و $2 \leq k$ عدداً صحيحاً، ولنأخذ المتغير العشوائي:

$$Y = g(X) := X \cdot (X-1) \cdot (X-2) \cdot \dots \cdot (X-k+1)$$

فعندئذ يدعى المقدار الآتي:

$$EY = E[g(X)] = E[X \cdot (X-1) \cdot (X-2) \cdot \dots \cdot (X-k+1)]$$

العزم العاملي (أو الضربي) من المرتبة k للمتغير العشوائي X The k^{th} Factorial Moment of X ، وسنرمز له بـ $\mathcal{F}_X^{(k)}$ وفي حال عدم وجود التباس (أي إننا نتعامل مع متغير عشوائي واحد فقط) سنرمز له بـ $\mathcal{F}^{(k)}$ على سبيل التبسيط. أي إنه من أجل $2 \leq k$ لدينا:

$$\mathcal{F}^{(k)} = E[X \cdot (X-1) \cdot (X-2) \cdot \dots \cdot (X-k+1)] \quad [7,34]$$

(٢, ٣, ٢, ٧) ملاحظة

إذا كان متغيراً عشوائياً X يملك عزماً ابتدائياً من المرتبة الثانية، فإنه يمكن حساب التباين لـ X باستخدام العزوم الابتدائية والعاملية أيضاً كما في العلاقة الآتية:

$$\text{var } X = E[X(X-1)] + EX(1-EX) = \mathcal{F}^{(2)} + \mu(1-\mu) \quad [7,35]$$

(٤, ٢, ٧) أمثلة (حساب العزوم لبعض المتغيرات العشوائية الشهيرة)

١- لنأخذ تجربة إلقاء حجر نرد متوازن لمرة واحدة فقط، وليكن X متغيراً عشوائياً فوق الفضاء الاحتمالي لهذه التجربة العشوائية معرّفاً من خلال العلاقة الآتية:

$$X(\omega) = \begin{cases} -1 & \text{for } \omega \geq 5 \\ 0 & \text{for } \omega = 3, 4 \\ +1 & \text{for } \omega \leq 2 \end{cases}$$

ولنقم بحساب القيمة الوسطى (أو المتوسط) لهذا المتغير العشوائي، ومن ثمّ حساب التباين والانحراف المعياري لهذا المتغير العشوائي.

الحل: لدينا تجربة إلقاء حجر نرد متوازن لمرة واحدة فقط، فعندئذ الفضاء الاحتمالي لهذه التجربة العشوائية هو $[\Omega, \mathcal{A}, P]$ علماً أنّ $\Omega = \{1, 2, 3, 4, 5, 6\}$ ، وسنأخذ الـ σ -جبر فوق Ω هو $\mathcal{A} = 2^\Omega$ ، وأما الدالة الاحتمالية P فيمكننا أخذها كما في العلاقة الآتية من أجل أي حادث $A \in \mathcal{A}$:

$$P(A) = \sum_{i: \omega_i \in A} Q(\{\omega_i\}) \quad ; \quad Q(\{\omega_i\}) = p_i = \frac{1}{6}, \quad i \in N_6$$

وذلك لأنّ حجر النرد متوازن. أما لحساب التباين للمتغير العشوائي المعطى فسوف نستخدم علاقة شتاينر [7,27]، وهذا يتطلب منا حساب EX أولاً، وبما أنّ المتغير العشوائي المعطى متقطعاً فإنّ $EX = \sum_{i \in I} x_i \cdot P(X = x_i)$ ، وبسبب توازن حجر النرد سيكون لدينا قيم الاحتمالات الكتلية هي: $P(X = -1) = \frac{1}{3}$ ، $P(X = 0) = \frac{1}{3}$ و $P(X = 1) = \frac{1}{3}$ ، وهذا يعني أنّ المتغير العشوائي X يخضع للتوزيع المنتظم المتقطع بمعلّمة $n = 3$ ، ومن ثمّ يكون لدينا:

$$EX = \sum_{i \in I} x_i \cdot P(X = x_i) = -1 \times \frac{1}{3} + 0 \times \frac{1}{3} + 1 \times \frac{1}{3} = 0$$

أي إن القيمة الوسطى (أو المتوسط) لهذا المتغير العشوائي تساوي الصفر. أما العزم الابتدائي من المرتبة الثانية لـ X فيحسب بأسلوب مماثل، حيث لدينا:

$$E X^2 = \sum_{i \in I} x_i^2 \cdot P(X = x_i) = (-1)^2 \times \frac{1}{3} + (0)^2 \times \frac{1}{3} + (1)^2 \times \frac{1}{3} = \frac{2}{3}$$

وباستخدام علاقة شتاينر تكون قيمة التباين لهذا المتغير العشوائي X هي:

$$\text{var } X = E X^2 - (E X)^2 = \frac{2}{3} - 0 = \frac{2}{3} = 0.667$$

ومن ثم يكون للانحراف المعياري القيمة الآتية:

$$\sigma = +\sqrt{\text{var } X} = +\sqrt{0.667} = 0.8167$$

٢- ليكن $X \sim U(c)$ (خاضعاً للتوزيع الوحيد النقطة)، ولنقم بحساب التوقع الرياضي والتباين لهذا المتغير العشوائي.

الحل: نعلم أن هذا المتغير العشوائي متقطع بمجموعة قيم $X = \{c\}$ ، وقانون توزيعه يعطى بالعلاقة $P(X = c) = 1$ ، فعندئذ يكون لدينا:

$$E X = \sum_{i \in I} x_i \cdot P(X = x_i) = c \cdot P(X = c) = c$$

وبالمثل نجد:

$$E X^2 = \sum_{i \in I} x_i^2 \cdot P(X = x_i) = c^2 \cdot P(X = c) = c^2$$

ومنه باستخدام علاقة شتاينر يكون لدينا:

$$\text{var } X = E X^2 - (E X)^2 = c^2 - (c)^2 = 0$$

في الواقع إن هذا النوع من المتغيرات العشوائية هو الوحيد الذي له تباين معدوم (يساوي الصفر) من بين جميع المتغيرات العشوائية التي تملك عزوماً ابتدائية من المرتبة الثانية. لا بل ويبرهن (سيترك كتمرين في آخر الفصل) على أن كل متغير عشوائي تباينه معدوم سيكون خاضعاً للتوزيع الوحيد النقطة.

لاحظ هنا أنه لا يمكن إيجاد علاقة تربط بين التباين والتوقع الرياضي لـ X إلا في الحالة الخاصة التي يكون فيها $c = 0$ ، وذلك لأن $\text{var } X = 0$ مهما تكن قيمة $E X$.

٢- ليكن X متغيراً عشوائياً خاضعاً للتوزيع الحداني $B(n, p)$ ، ولنقم بحساب التوقع الرياضي والتباين لهذا المتغير العشوائي.

الحل: نعلم أن هذا المتغير العشوائي متقطع بمجموعة قيم $X = \{0, 1, 2, \dots, n\}$ مع $N \ni n$ قيمة مثبتة، وقانون توزيعه يعطى بالعلاقة الآتية:

$$P(X = k) = \binom{n}{k} \cdot p^k \cdot (1-p)^{n-k}$$

علماً أن $0 < p < 1$ ، فعندئذ نجد أن:

$$\begin{aligned}
 \mathbf{E}X &= \sum_{k=0}^n k \cdot P(X=k) = \sum_{k=1}^n k \cdot \binom{n}{k} \cdot p^k \cdot (1-p)^{n-k} = \sum_{k=1}^n k \cdot \frac{n!}{k!(n-k)!} \cdot p^k \cdot (1-p)^{n-k} \\
 &= n p \sum_{k=1}^n \frac{(n-1)!}{(k-1)! [(n-1)-(k-1)]!} \cdot p^{k-1} \cdot (1-p) \\
 &\stackrel{\substack{n-1=m \\ k-1=\ell}}{=} n p \sum_{\ell=0}^m \underbrace{\frac{(m)!}{\ell! (m-\ell)!} \cdot p^{\ell} \cdot (1-p)^{m-\ell}}_{=1} = n \cdot p
 \end{aligned}$$

وأما من أجل حساب تباين هذا المتغير العشوائي فإننا نلاحظ صعوبة حسابه باستخدام التعريف أو باستخدام علاقة شتاينر التي تعتمد على العزم من المرتبة الأولى، والثانية (حيث نلاحظ عدم جدوى استخدام تعريف العزم من المرتبة الثانية لحساب $\mathbf{E}X^2$)، ولذلك سنستخدم العزوم العاملة من المرتبة الثانية، حيث لدينا:

$$\begin{aligned}
 \mathcal{F}^{(2)} &= \mathbf{E}[X(X-1)] = \sum_{k=0}^n k(k-1) \cdot P(X=k) \\
 &= \sum_{k=2}^n k(k-1) \cdot \binom{n}{k} \cdot p^k \cdot (1-p)^{n-k} = \sum_{k=2}^n k(k-1) \cdot \frac{n!}{k!(n-k)!} \cdot p^k \cdot (1-p)^{n-k}
 \end{aligned}$$

ومن ثم يمكننا أن نكتب:

$$\begin{aligned}
 \mathcal{F}^{(2)} &= n(n-1)p^2 \sum_{k=2}^{n-2} \frac{(n-2)!}{(k-2)! [(n-2)-(k-2)]!} p^{k-2} (1-p)^{(n-2)-(k-2)} \\
 &\stackrel{\substack{n-2=m \\ k-2=\ell}}{=} n(n-1)p^2 \sum_{\ell=0}^m \underbrace{\frac{(m)!}{\ell! (m-\ell)!} \cdot p^{\ell} \cdot (1-p)^{m-\ell}}_{=1} = n(n-1)p^2
 \end{aligned}$$

ومنه يصبح لدينا:

$$\mathbf{var} X = \mathbf{E}[X(X-1)] + \mathbf{E}X(1-\mathbf{E}X) = n(n-1)p^2 + n p(1-n p) = n p(1-p)$$

وهنا لاحظ هنا أنه ثمة علاقة تربط بين التباين والتوقع الرياضياتي لهذا المتغير العشوائي، حيث لدينا:

$$\mathbf{var} X = (1-p) \mathbf{E}X$$

وكتطبيق على هذا المثال سنفترض أن شخصاً يقوم بكتابة نص مكون من 5000 حرف، وأن احتمال خطأ هذا الشخص في كتابة حرف أثناء التنضيد يساوي 0.01، وأن كتابة كل حرف غير متأثرة بالحروف التي كتبت قبلها ولا تأثر على كتابة الحروف التي تليها. عندئذ إذا كان X متغيراً عشوائياً راصداً لعدد الحروف التي كتبت خطأ فإن X سيكون خاضعاً للتوزيع الحداني $B(5000, 0.01)$ ، ومن ثم يكون متوسط عدد الحروف التي كتبت خطأ في هذا النص يساوي:

$$\mathbf{E}X = n \cdot p = (5000) \cdot (0.01) = 50$$

بانحراف معياري يساوي:

$$\sigma = +\sqrt{\mathbf{var} X} = +\sqrt{n p(1-p)} = +\sqrt{(5000)(0.01)(1-0.01)} = 7.0356$$

أي إنه من المتوقع أن يكون عدد الحروف التي كتبت خطأ في هذا النص ما بين 43 و57 حرفاً تقريباً.

٣- ليكن X متغيراً عشوائياً خاضعاً للتوزيع الهندسي $G(p)$ ، ولنقم بحساب قيمته المتوقعة ومن ثم تباينه.

الحل: نعلم أن هذا المتغير العشوائي متقطع بمجموعة قيم $X = \mathbb{N}$ ، وقانون توزيع $P(X=k) = p(1-p)^{k-1}$ مع

ومن ثم فإن القيمة المتوقعة لهذا المتغير العشوائي هي:

$$EX = \sum_{k=1}^{\infty} k \cdot P(X = k) = \sum_{k=1}^{\infty} k p (1-p)^{k-1} = p \sum_{k=1}^{\infty} k (1-p)^{k-1} = p \frac{d}{d(1-p)} \left(\sum_{k=1}^{\infty} (1-p)^k \right) = \frac{1}{p}$$

وهكذا نجد أن متوسط قيم هذا المتغير العشوائي يساوي مقلوب قيمته p ، وأما لحساب التباين فإننا سنقوم أولاً بحساب العزم العامل من المرتبة الثانية، حيث لدينا:

$$\begin{aligned} \mathcal{F}^{(2)} = E[X(X-1)] &= \sum_{k=1}^{\infty} k(k-1)P(X=k) = \sum_{k=2}^{\infty} k(k-1)p(1-p)^{k-1} \\ &= p(1-p) \frac{d^2}{d(1-p)^2} \left(\sum_{k=2}^{\infty} (1-p)^k \right) = \frac{2(1-p)}{p^2} \end{aligned}$$

ومن ثم يكون لدينا:

$$\text{var } X = \frac{2(1-p)}{p^2} + \frac{1}{p} - \left(\frac{1}{p} \right)^2 = \frac{1-p}{p^2}$$

فلاحظ هنا أن العلاقة التي تربط بين التباين والتوقع الرياضي لهذا المتغير العشوائي هي $\text{var } X = \frac{1-p}{p} EX$.

كتطبيق على هذا المثال لنأخذ المثال السابق، ولكن هنا سنفترض أن الشخص سيتوقف عن الكتابة عند وقوع أول خطأ له في التنضيد، فعندئذ إذا كان X متغيراً عشوائياً راصداً لعدد الحروف التي سيكتبها حتى يُخطئ لأول مرة، فإن هذا المتغير العشوائي سيكون خاضعاً للتوزيع الهندسي $G(0.01)$ ، ومن ثم يكون متوسط عدد الحروف التي سيكتبها حتى يُخطئ لأول مرة يساوي:

$$EX = \frac{1}{p} = \frac{1}{0.01} = 100$$

وبانحراف معياري قدره:

$$\sigma = +\sqrt{\text{var } X} = +\sqrt{\frac{1-p}{p^2}} = +\sqrt{\frac{1-0.01}{0.01^2}} = 99.499$$

ملاحظ هنا كبر قيمة الانحراف المعياري لهذا المتغير العشوائي، ومن ثم من المتوقع أن يكون عدد الحروف التي سيكتبها حتى يُخطئ لأول مرة ما بين 1 و 199 حرفاً تقريباً، وهذا يعني أنه من المتوقع ألا يكتب ولا حرف صحيح ويتوقف عن الكتابة من أول حرف يكتبه، أو أن يصل عدد الحروف الصحيحة التي سيكتبها 199 حرفاً قبل توقفه عن الكتابة.

٤- ليكن X متغيراً عشوائياً خاضعاً للتوزيع الأسّي $EX(\lambda)$ ولنقم بحساب التباين لهذا المتغير العشوائي.

الحل: نعلم أن هذا المتغير العشوائي مستمر بدالة كثافة احتمالية:

$$f_X(x) = \lambda e^{-\lambda x} \cdot \mathbf{I}_{[0, +\infty)}(x) \quad ; \quad \forall x \in \mathbb{R}$$

علماً أن $0 < \lambda$ ثابت، ولنقم بحساب العزوم الابتدائي من المرتبة الأولى والثانية لهذا المتغير العشوائي، فنجد كما يلي:

$$EX = \int_{-\infty}^{+\infty} x \cdot \lambda e^{-\lambda x} \cdot \mathbf{I}_{[0, +\infty)}(x) dx = \int_0^{+\infty} \lambda x \cdot e^{-\lambda x} dx = \frac{1}{\lambda} \int_0^{+\infty} y \cdot e^{-y} dy = \frac{1}{\lambda} \cdot \Gamma(2) = \frac{1}{\lambda}$$

علماً أن $\Gamma(x)$ ترمز إلى دالة غاما، حيث لدينا:

$$\int_0^{+\infty} x^n e^{-x} dx = \Gamma(n+1) = n!$$

ولنحسب الآن EX^2 فنجد ما يلي:

$$\begin{aligned} EX^2 &= \int_{-\infty}^{+\infty} x^2 \cdot \lambda e^{-\lambda x} \cdot I_{[0, +\infty)}(x) dx \\ &= \int_0^{+\infty} \lambda x^2 \cdot e^{-\lambda x} dx = \frac{1}{\lambda^2} \int_0^{+\infty} y^2 \cdot e^{-y} dy = \frac{1}{\lambda^2} \cdot \Gamma(3) = \frac{2}{\lambda^2} \end{aligned}$$

ومن ثم يكون بحسب علاقة شتاينر لدينا:

$$\text{var } X = EX^2 - (EX)^2 = \frac{2}{\lambda^2} - \left(\frac{1}{\lambda}\right)^2 = \frac{1}{\lambda^2}$$

فلاحظ هنا أن العلاقة التي تربط بين التباين والتوقع الرياضياتي لهذا المتغير العشوائي هي:

$$\text{var } X = (EX)^2$$

كتطبيق على هذا المثال لنفترض أن لدينا جهازاً كهربائياً عمره يخضع للتوزيع الأسّي بمعلمة $\lambda = 0.01$ ساعة عمل (في الواقع توجد الكثير من الأجهزة الكهربائية التي عمرها الافتراضي يخضع للتوزيع الأسّي)، ولنقم بحساب متوسط عمر هذا الجهاز وتعيين أقل وأطول عمر مفترض له.

من أجل ذلك لنفترض أن X متغيراً عشوائياً راصداً لعمر هذا الجهاز، فعندئذ سيكون X خاضعاً للتوزيع الأسّي $EX(0.01)$ ، ومن ثم يكون متوسط عمر هذا الجهاز يساوي:

$$\mu = EX = \frac{1}{\lambda} = \frac{1}{0.01} = 100$$

وهكذا نجد أن متوسط عمر هذا الجهاز يساوي 100 ساعة عمل، وأما لتعيين أقل وأطول عمر مفترض له فإننا بحاجة لحساب الانحراف المعياري لـ X ، فنجد بوساطة حساب التباين كما يلي:

$$\text{var } X = \frac{1}{\lambda^2} = \frac{1}{0.0001} = 10000$$

ومن ثم يكون $\sigma = +\sqrt{\text{var } X} = 100$ ، وهذا يعني أنه من المتوقع أن يعمر الجهاز لمدة تساوي $\mu \pm \sigma$ ، وهذا يعني أنه من المتوقع أن نجد الجهاز معطلاً منذ بدء تشغيله كما يمكن له أن يعمل حتى 200 ساعة عمل.

٥- ليكن X متغيراً عشوائياً خاضعاً للتوزيع الطبيعي $N(\mu, \sigma)$ ، ولنقم بحساب التوقع الرياضياتي لهذا المتغير العشوائي.

الحل: نعلم أن هذا المتغير العشوائي مستمر بدالة كثافة احتمالية:

$$f_X(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right] ; \forall x \in \mathbb{R}$$

علماً أن $\mu \in \mathbb{R}$ و $0 < \sigma$ (ثوابت) هما معلمتي التوزيع، ولنقم أولاً بحساب العزم الابتدائي من المرتبة الأولى لهذا المتغير العشوائي فنجد الآتي:

$$\begin{aligned} EX &= \int_{-\infty}^{\infty} x f_X(x) dx = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^{\infty} x \cdot \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right] dx = \frac{\sqrt{2} \cdot \sigma}{\sigma\sqrt{2\pi}} \int_{-\infty}^{\infty} \frac{(x-\mu)+\mu}{\sqrt{2} \cdot \sigma} \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right] dx \\ &= \underbrace{\frac{\sqrt{2} \cdot \sigma}{\sigma\sqrt{2\pi}} \int_{-\infty}^{\infty} \frac{(x-\mu)}{\sqrt{2} \cdot \sigma} \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right] dx}_{=0} + \underbrace{\mu \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^{\infty} \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right] dx}_{=1} = \mu \end{aligned}$$

كما يمكن إثبات (ترك كتمرين في آخر الفصل) أن تباين هذا المتغير العشوائي يساوي σ^2 ، أي إن $\text{var } X = \sigma^2$ ، فلاحظ هنا أنه لا توجد علاقة نظرية محددة تربط بين قيمة التباين والتوقع الرياضي لهذا المتغير العشوائي (ولهذا الكلام معنى سنذكره لاحقاً في نظرية المعاينة).

كتطبيق على هذا المثال لنفترض أنه لدينا آلة لإنتاج نوع من القضبان المعدنية ذات قطر يساوي 12 مم، فإذا علمنا أن قيم أقطار القضبان المنتجة من قبل هذه الآلة تخضع للتوزيع الطبيعي بمتوسط 12 مم وانحراف معياري 0.5 مم (في الواقع يوجد الكثير من القياسات العملية تخضع للتوزيع الطبيعي)، فإذا أخذنا قضيباً ما من إنتاج هذه الآلة فما هو احتمال ألا يقل قطره عن 12 مم؟

الحل: من أجل ذلك لنفترض أن X متغيراً عشوائياً راصداً لقطر القضيب المنتج من هذه الآلة، فعندئذ سيكون X خاضعاً للتوزيع الطبيعي $N(12, 0.5)$ ، ومن ثم يكون الاحتمال المطلوب هو $P(X \geq 12)$ ، ولحساب هذا الاحتمال لدينا:

$$P(X \geq 12) = 1 - P(X < 12) = 1 - P\left(\frac{X - \mu}{\sigma} < \frac{12 - \mu}{\sigma}\right) = 1 - P(Z < 0) = 1 - 0.5 = 0.5$$

حيث قمنا باستيعار المتغير العشوائي X باستخدام التحويل $Z = \frac{X - 12}{0.5}$ ، ولدينا من جدول التوزيع الطبيعي $P(Z < 0) = 0.5$.

(٥, ٢, ٧) متباينات شهيرة ذات صلة بالعزوم

قد نكون في بعض الأحيان بحاجة إلى تقدير قيمة الحد الأدنى لقيمة التباين لمتغير عشوائي X . في هذا المجال تقدم لنا المتباينة الآتية تقديراً جيداً لقيمة تباين متغير عشوائي X .

(١, ٥, ٢, ٧) مبرهنة (متباينة تشبشيف Chebyshev inequality)

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ مع $EX^2 < +\infty$ ، فعندئذ من أجل أي $0 < \varepsilon$ تكون المتباينة الآتية محققة:

$$\text{var } X \geq \varepsilon^2 \cdot P\left((X - EX)^2 \geq \varepsilon^2\right) \quad [7,36-a]$$

وهذه المتباينة تُعرف باسم متباينة تشبشيف.

البرهان: بملاحظة أن المتغير العشوائي $Y = (X - EX)^2$ غير سالب ويملك توقعاً رياضياً لأن $EX^2 < +\infty$ ، فإنه بحسب متباينة ماركوف [7,19-a] سيكون الآتي محققاً من أجل أي $\varepsilon^2 = \delta > 0$:

$$\text{var } X = EY \geq \delta \cdot P(Y \geq \delta) = \varepsilon^2 \cdot P\left((X - EX)^2 \geq \varepsilon^2\right)$$

وبذلك يتم البرهان.

(٢, ٥, ٢, ٧) ملاحظات

١ - من المتباينة [7,36-a] يمكننا أن نكتب الآتي من أجل كل $0 < x$:

$$\frac{\text{var } X}{x} \geq 1 - P\left((X - EX)^2 < x\right) = 1 - F_{(X-EX)^2}(x)$$

والتي نجد منها:

$$F_{(X-EX)^2}(x) \geq 1 - \frac{\text{var} X}{x} \quad [7,36-b]$$

وهذه العلاقة تساعدنا في تقدير قيمة دالة التوزيع الاحتمالية للمتغير العشوائي $Y = (X - EX)^2$.

٢- تُعدّ متباينة تشبيشيف من أفضل المتباينات المستخدمة لتقدير قيمة تباين متغير عشوائي يملك عزوماً ابتدائية من المرتبة الثانية على الأقل.

٣- من متباينة كوشي-شفارتز (المبرهنة (٧, ٢, ١, ٨)) يمكننا الحصول على المتباينة الآتية:

$$[\text{cov}(X, Y)]^2 \leq \text{var} X \cdot \text{var} Y \quad [7,37-a]$$

ويتم ذلك من خلال تطبيق تلك المتباينة على المتغيرين العشوائيين $X = (U - EU)$ و $Y = (T - ET)$ ، علماً أنّ U و T متغيرين عشوائيين فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ مع $EU^2 < +\infty$ و $ET^2 < +\infty$. أكثر من ذلك تُمكننا المتباينة السابقة [7,37-a] من تقدير قيمة التباين لأحد المتغيرين العشوائيين X أو Y بدلالة قيمة تباينهما والتباين للمتغير الآخر، وذلك كما يلي:

$$\text{var} Y \geq \frac{1}{\text{var} X} [\text{cov}(X, Y)]^2 \quad [7,37-b]$$

(٧, ٢, ٦) معامل الارتباط الخطي لمتغيرين عشوائيين Linear Correlation Coefficient of two R.V.

لقد رأينا في الفصل الثالث من هذا الكتاب أنّه من المقاييس المهمة التي تعتمد على العزوم المركزية لمجموعتي بيانات هو الارتباط الخطي بين هاتين المجموعتين، حيث لاحظنا أنّ البيانات تتولّد عادة من متغيرات، ولذلك فإنّ هذا المفهوم ينسحب على المتغيرات العشوائية أيضاً، ولكن بفارق وحيد هو أنّ القيم التي ستعامل معها في هذا القطّاع هي قيم عشوائية حتماً. التعريف الآتي يقدم لنا كيفية حساب معامل الارتباط الخطي بين متغيرين عشوائيين.

(٧, ٢, ٦, ١) تعريف معامل الارتباط الخطي لمتغيرين عشوائيين

ليكن X و Y متغيرين عشوائيين فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، وكلّ منهما يملك عزوماً ابتدائية من المرتبة الثانية، فعندئذٍ نرمز بـ $\rho_{X,Y}$ لمعامل الارتباط الخطي بين المتغيرين العشوائيين X و Y ، ويُعرف من خلال العلاقة الآتية:

$$\rho_{X,Y} := \begin{cases} \frac{\text{cov}(X, Y)}{\sqrt{\text{var} X} \sqrt{\text{var} Y}} & \text{for } \text{var} X > 0 \text{ and } \text{var} Y > 0 \\ 0 & \text{otherwise} \end{cases} \quad [7,38]$$

(٧, ٢, ٦, ١) ملاحظات

١- إذا كان X مستقلاً عن Y ، فعندئذٍ سيكون $\rho_{X,Y} = 0$ ، ولكنّ عكس هذه النتيجة غير صحيح، بمعنى أنّه إذا كان $\rho_{X,Y} = 0$ فإنّ ذلك لا يعني بالضرورة أن يكون X و Y مستقلّان بعضهما عن بعض (أوجد مثلاً مناسباً على ذلك).

٢- من الواضح أنّ $-1 \leq \rho_{X,Y} \leq +1$ ، وأنّ هذا الارتباط يكون إيجابياً إذا كان $0 < \rho_{X,Y}$ ، وعكسياً إذا كان $0 > \rho_{X,Y}$ ، وعندما يصبح $\rho_{X,Y} = \pm 1$ فعندئذٍ يكون المتغيرين العشوائيين X و Y مرتبطين مع بعضهما بعلاقة خطية، أي أنّه يمكننا أن نكتب:

$$Y = a + bX$$

أوجد مثلاً مناسباً على كلّ حالة من هذه الحالات المذكورة آنفاً.

٣- بقية الخصائص لهذا المعامل تناقش بشكل مماثل كما مرّ معنا سابقاً (في الفصل الثالث) بخصوص معامل الارتباط الخطي.

(٧,٣) الدالة المولدة الاحتمالية**Probability Generating Function**

إن الدوال المولدة الاحتمالية تقوم بدور مهم في تعيين الكثير من التوزيعات الاحتمالية للمتغيرات العشوائية، حتى إن بعض التوزيعات الاحتمالية الشهيرة سميت وفقاً للنموذج الرياضي للدالة المولدة الاحتمالية له، ومثال على ذلك التوزيع الهندسي وفوق الهندسي، وذلك لأن الدالة المولدة الاحتمالية لمتغير عشوائي خاضع للتوزيع الهندسي هي دالة هندسية في حين أن الدالة المولدة الاحتمالية لمتغير عشوائي خاضع للتوزيع فوق الهندسي هي دالة فوق هندسية.

(٧,٣,١) تعريف (الدالة المولدة الاحتمالية لمتغير عشوائي)

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، ولنعرّف من أجل هذا المتغير العشوائي دالة حقيقية G_X على \mathbb{R} كما يلي:

$$G_X : \mathbb{R} \longrightarrow \mathbb{R} \quad ; s \mapsto G_X(s) := E s^X \quad [7,39-a]$$

فعندئذ تدعى G_X الدالة المولدة الاحتمالية للمتغير العشوائي X .

(٧,٣,١,١) ملاحظات

١- إذا كان X متغيراً عشوائياً متقطعاً مجموعة قيمه $X = \{x_i ; i \in I\}$ ، فعندئذ يصبح للدالة المولدة الاحتمالية لـ X العرض الآتي:

$$G_X(s) = \sum_{i \in I} s^{x_i} P(X = x_i) \quad [7,39-b]$$

وفي حال كانت مجموعة قيمه $X = \mathbb{N}$ ، فعندئذ تكتب الدالة المولدة الاحتمالية لـ X على النحو الآتي:

$$G_X(s) = \sum_{k \in \mathbb{N}} s^k P(X = k) \quad [7,39-c]$$

ولكي يملك المتغير العشوائي X دالة مولدة احتمالية يجب أن تكون أي من المتسلسلتين العدديتين [7,39-b] و [7,39-c] متقاربة مطلقاً، حيث نلاحظ أن المتسلسلة العددية الأخيرة تكون متقاربة من أجل جميع قيم s المحققة للمتباعدة $|s| \geq 1$.

٢- إذا كان X متغيراً عشوائياً مستمراً بدالة كثافة احتمالية f_X ، فعندئذ يصبح للدالة المولدة الاحتمالية لـ X العرض الآتي:

$$G_X(s) = \int_{-\infty}^{\infty} s^x f_X(x) dx \quad [7,39-d]$$

ولكي يملك متغير عشوائي مستمر X دالة مولدة احتمالية يجب أن يكون التكامل المعتل في العلاقة [7,39-d] متقارباً مطلقاً.

(٧,٣,١,٢) أمثلة

١- لنأخذ $X \sim D(c)$ ، فعندئذ يكون لدالته المولدة الاحتمالية العرض الآتي:

$$G_X(s) = s^c \quad ; \forall s \in \mathbb{R}$$

وذلك لأنه من أجل كل $s \in \mathbb{R}$ لدينا:

$$G_X(s) = E(s^X) = \sum_{k \in I} s^{x_k} P(X = x_k) = s^c \cdot P(X = c) = s^c$$

٢- لنأخذ $X \sim \mathbf{B}(n, p)$ ، فعندئذ يكون لدالته المولدة الاحتمالية العرض الآتي:

$$\mathbf{G}_X(s) = [p(s-1) + 1]^n \quad ; \forall s \in \mathbb{R}$$

وذلك لأنه من أجل كل $s \in \mathbb{R}$ لدينا:

$$\begin{aligned} \mathbf{G}_X(s) &= \mathbf{E}(s^X) = \sum_{i \in I} s^{x_i} P(X = x_i) = \sum_{k=0}^n s^k P(X = k) = \sum_{k=0}^n s^k \cdot \binom{n}{k} \cdot p^k \cdot (1-p)^{n-k} \\ &= \sum_{k=0}^n \binom{n}{k} \cdot (sp)^k \cdot (1-p)^{n-k} = [sp + (1-p)]^n = [p(s-1) + 1]^n \end{aligned}$$

٣- لنأخذ $X \sim \mathbf{G}(p)$ ، فعندئذ يكون لدالته المولدة الاحتمالية العرض الآتي:

$$\mathbf{G}_X(s) = \frac{ps}{1-s(1-p)} \quad ; \forall s \in \mathbb{R}$$

وذلك لأنه من أجل كل $s \in \mathbb{R}$ لدينا:

$$\mathbf{G}_X(s) = \mathbf{E}(s^X) = \sum_{k=1}^{\infty} s^k P(X = k) = \sum_{k=1}^{\infty} s^k (1-p)^{k-1} \cdot p = sp \sum_{\ell=0}^{\infty} (s(1-p))^{\ell} = \frac{ps}{1-s(1-p)}$$

حيث نلاحظ أن الطرف الأيمن من العلاقة الأخيرة هي صيغة لدالة هندسية، ومن أجل الحالة الخاصة $p = \frac{1}{2}$ (التساوي في النصيب للتجربة البرنولية) يصبح لدينا:

$$\mathbf{G}_X(s) = \sum_{k=1}^{\infty} s^k \frac{1}{2} \left(\frac{1}{2} \right)^{k-1} = \frac{s}{2-s} \quad ; \forall s \in \mathbb{R} \setminus \{2\}$$

٤- لنأخذ $X \sim \mathbf{P}(\lambda)$ ، فعندئذ يكون لدالته المولدة الاحتمالية العرض الآتي:

$$\mathbf{G}_X(s) = \exp \{ \lambda(s-1) \} \quad ; \forall s \in \mathbb{R}$$

وذلك لأنه من أجل كل $s \in \mathbb{R}$ لدينا:

$$\mathbf{G}_X(s) = \mathbf{E} s^X = \sum_{k=0}^{\infty} s^k P(X = k) = \sum_{k=0}^{\infty} s^k \frac{\lambda^k}{k!} e^{-\lambda} = e^{-\lambda} \sum_{k=0}^{\infty} \frac{(\lambda s)^k}{k!} = e^{-\lambda} e^{\lambda s} = e^{\lambda(s-1)}$$

٥- لنأخذ $X \sim \mathbf{U}([a, b])$ ، فعندئذ يكون لدالته المولدة الاحتمالية العرض الآتي:

$$\mathbf{G}_X(s) = \frac{s^b - s^a}{(b-a) \ln s} \quad ; \forall s \in \mathbb{R}$$

وذلك لأنه من أجل كل $s \in \mathbb{R}$ لدينا:

$$\mathbf{G}_X(s) = \int_{-\infty}^{\infty} s^x f_X(x) dx = \frac{1}{b-a} \int_a^b s^x dx = \frac{1}{b-a} \left(\frac{s^x}{\ln s} \Big|_a^b \right) = \frac{s^b - s^a}{(b-a) \ln s}$$

(٢, ٣, ٧) خصائص الدالة المولدة الاحتمالية

المبرهنة الآتية التي سنقبلها دون برهان تقدم لنا بعض الخصائص المهمة للدالة المولدة الاحتمالية التي تساعدنا في حساب العزوم للمتغيرات العشوائية التي تملك عزوماً ابتدائية.

(٧, ٣, ٢, ١) مبرهنة

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ بدالة مولدة احتمالية G_X ويملك عزماً ابتدائياً حتى المرتبة k مع $N \ni k$ كيفي ولكن مثبت، فعندئذ سيكون لدينا ما يلي محققاً:

- a) $G_X(1) = 1$
- b) $G_X(0) = P(X = 0)$
- c) $EX = G'_X(1)$
- d) $E[X \cdot (X-1) \cdot \dots \cdot (X-k+1)] = \lim_{s \uparrow 1} G_X^{(k)}(s)$

علماً أنَّ $G_X^{(k)}(s)$ هو المشتق من المرتبة k للدالة G_X عند النقطة s ، ويشار في بعض الأحيان إلى المقدار $\lim_{s \uparrow 1} G_X^{(k)}(s)$ بالرمز $G_X^{(k)}(1)$ أي إنه يكتب:

$$E[X \cdot (X-1) \cdot \dots \cdot (X-k+1)] = G_X^{(k)}(1)$$

(٧, ٣, ٢, ٢) أمثلة

١- لنأخذ $X \sim D(c)$ ، فعندئذ يكون من أجل كل $s \in \mathbb{R}$ لدينا:

$$G'_X(s) = c \cdot s^{c-1} \quad \& \quad G''_X(s) = c(c-1) \cdot s^{c-2} \quad \& \quad G'''_X(s) = c(c-1)(c-2) \cdot s^{c-3}$$

ومن ثم يكون بحسب المبرهنة السابقة (٧, ٣, ٢, ١) لدينا ما يلي:

$$EX = G'_X(1) = c \cdot s^{c-1} \Big|_{s=1} \Rightarrow G'_X(1) = c$$

وكذلك:

$$E[X \cdot (X-1)] = G''_X(1) = c(c-1) \cdot s^{c-2} \Big|_{s=1} = c(c-1)$$

ومنه ينتج لدينا أنَّ:

$$EX^2 = E[X \cdot (X-1)] + EX = c(c-1) + c = c^2$$

وكذلك نجد:

$$EX^3 = E[X \cdot (X-1) \cdot (X-2)] + 3EX^2 - 2EX = c(c-1)(c-2) + 3c^2 - 2c = c^3$$

وباستخدام صيغة شتاينر نجد أنَّ التباين لهذا المتغير العشوائي يساوي الصفر، حيث لدينا:

$$\text{var } X = EX^2 - (EX)^2 = \mu^{(2)} - \mu^2 = c^2 - c^2 = 0$$

وهي ذات النتيجة التي وصلنا إليها سابقاً بخصوص التباين لهذا النوع من المتغيرات العشوائية.

٢- لنأخذ $X \sim B(n, p)$ ، فعندئذ يكون من أجل كل $s \in \mathbb{R}$ لدينا:

$$G'_X(s) = \left([p(s-1)+1]^n \right)' = n p [p(s-1)+1]^{n-1}$$

ومن ثم يكون لدينا بحسب المبرهنة السابقة (٧, ٣, ٢, ١) ما يلي:

$$EX = G'_X(1) = n p [p(s-1)+1]^{n-1} \Big|_{s=1} = n p$$

وهي ذات القيمة التي حصلنا عليها سابقاً ولكن هنا بطريقة أسهل وأسرع في الحساب. كذلك لدينا:

$$\mathbf{E} [X \cdot (X - 1)] = \mathbf{G}_X''(1) = n(n-1)p^2 [p(s-1)+1]^{n-2} \Big|_{s=1} = n(n-1)p^2$$

ومنهُ ينتج لدينا أنَّ:

$$\mathbf{E} X^2 = \mathbf{E} [X \cdot (X - 1)] + \mathbf{E} X = n(n-1)p^2 + np = np[(n-1)p+1] = [(n-1)p+1] \cdot \mathbf{E} X$$

وبالمثل نجد:

$$\mathbf{E} [X(X-1)(X-2)] = \mathbf{G}_X'''(1) = n(n-1)(n-2)p^3 [p(s-1)+1]^{n-3} \Big|_{s=1} = n(n-1)(n-2)p^3$$

ومن ثَمَّ ينتج لدينا:

$$\begin{aligned} \mathbf{E} X^3 &= \mathbf{E} [X \cdot (X-1) \cdot (X-2)] + 3\mathbf{E} X^2 - 2\mathbf{E} X = n(n-1)(n-2)p^3 + 3n(n-1)p^2 - 2np \\ &= np(n^2p^2 - 3np^2 + 2p^2 + 3np - 3p - 2) = [(n^2 - 3n + 2)p^2 + (3n - 3)p - 2] \cdot \mathbf{E} X \end{aligned}$$

٣- لنأخذ $X \sim \mathbf{G}(p)$ ، فعندئذ يكون من أجل كل $s \in \mathbb{R}$ لدينا:

$$\mathbf{G}_X'(s) = \left(\frac{ps}{1-s(1-p)} \right)' = \frac{p[1-s(1-p)] + (1-p)ps}{[1-s(1-p)]^2}$$

ومن ثَمَّ يكون لدينا بحسب المبرهنة السابقة (١, ٢, ٣, ٧) ما يلي:

$$\mathbf{E} X = \mathbf{G}_X'(1) = \frac{p[1-s(1-p)] + (1-p)ps}{[1-s(1-p)]^2} \Big|_{s=1} = \frac{p^2 + (1-p)p}{p^2} = \frac{1}{p}$$

وهي ذات القيمة التي حصلنا عليها سابقاً، ولكن هنا بطريقة أسهل، ودون التطرق لاشتقاق المتسلسلات الدالية.

إنَّ نظرية الاحتمالات كثيراً ما تهتمُّ بمجاميع لمتغيرات عشوائية، ولدراسة مثل هذه المجاميع نحتاج إلى طريقة مفيدة وفعالة لوصف توزيع هذه المجاميع. في الواقع، وكما ذكرنا آنفاً، أثبتت الدوال المولدة الاحتمالية أنَّها مصدر قوة في هذا المجال، فلو كان X و Y متغيرين عشوائيين متقطعين ومستقلين فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ الدالة الاحتمالية لمجموعهما تُعطى بالعلاقة الآتية:

$$P(X + Y = u) = \sum_{x \in \mathbf{X}} P(X = x) \cdot P(Y = u - x)$$

والذي يلزمنا بحسابات معقَّدة في الحالة العامَّة. في مقابل ذلك نجد أنَّ الدوال المولدة الاحتمالية تُبدي طريقة مختصرة لتعيين توزيع مثل هذا المجموع.

المبرهنة الآتية تُمكننا من تعيين الدالة المولدة الاحتمالية لمجموع متغيرات عشوائية مستقلة بدلالة الدوال المولدة الاحتمالية لكلِّ منها، وبدورها يمكن أن تكشف لنا عن توزيع مجموع المتغيرات العشوائية المستقلة.

(٣, ٢, ٣, ٧) مبرهنة

ليكن X_1, X_2, \dots, X_n متغيرات عشوائية مستقلة فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ تكون العلاقة الآتية مُحَقَّقة:

$$\mathbf{G}_{X_1 + X_2 + \dots + X_n}(s) = \prod_{k=1}^n \mathbf{G}_{X_k}(s) \quad ; \forall s \in \mathbb{R} \quad [7,40]$$

البرهان: بما أن المتغيرات العشوائية X_1, X_2, \dots, X_n مستقلة، فعندئذ من أجل كل $s \in \mathbb{R}$ ستكون المتغيرات العشوائية $s^{X_1}, s^{X_2}, \dots, s^{X_n}$ مستقلة أيضاً، ومنه ينتج أنه من أجل كل $s \in \mathbb{R}$ سيكون الآتي محققاً:

$$G_{X_1+X_2+\dots+X_n}(s) = E s^{X_1+X_2+\dots+X_n} = E \left(\prod_{k=1}^n s^{X_k} \right) = \prod_{k=1}^n E s^{X_k} = \prod_{k=1}^n G_{X_k}(s)$$

وبهذا يتم المطلوب.

(٤, ٢, ٣, ٧) أمثلة

١- لتكن X_1, X_2, \dots, X_n متغيرات عشوائية برنولية مستقلة ولكل منها المعلمة p نفسها مع $0 < p < 1$ ، ولناخذ المجموع الآتي من أجل $n \in \mathbb{N}$ كفي ولكن مثبت:

$$S_n = X_1 + X_2 + \dots + X_n \quad (*)$$

ف نجد أن الدالة المولدة الاحتمالية لـ X_k من أجل $k \in \mathbb{N}_n$ هي:

$$G_{X_k}(s) = (1-p)s^0 + ps^1 = (1-p) + ps \quad ; \forall s \in \mathbb{R}$$

ومن ثم يكون للدالة المولدة الاحتمالية للمتغير العشوائي S_n العرض الآتي:

$$G_{S_n}(s) = [G_{X_k}(s)]^n = [(1-p) + ps]^n \quad ; \forall s \in \mathbb{R}$$

وهذه الصيغة الأخيرة هي صيغة الدالة المولدة الاحتمالية لمتغير عشوائي خاضع للتوزيع الحداني بمعلمتين n و p ، أي إن لـ S_n توزيع حداني $B(n, p)$.

٢- ليكن لدينا $X_1 \sim B(n_1, p)$ و $X_2 \sim B(n_2, p)$ متغيرين عشوائيين مستقلين، فعندئذ نجد ما يلي:

$$G_{X_1+X_2}(s) = G_{X_1}(s) \cdot G_{X_2}(s) = [(1-p) + ps]^{n_1+n_2} \quad ; \forall s \in \mathbb{R}$$

وهذه الصيغة الأخيرة هي صيغة الدالة المولدة الاحتمالية لمتغير عشوائي خاضع للتوزيع الحداني بمعلمتين $n = n_1 + n_2$ و p ، ومن ثم يكون لمجموع المتغيرين العشوائيين المستقلين المعطيين توزيع حداني بمعلمتين $n = n_1 + n_2$ و p . أي إن:

$$X_1 + X_2 := X \sim B(n_1 + n_2, p)$$

في الواقع تصادفنا في بعض المسائل حالات يكون فيها عدد المتغيرات العشوائية n نفسه هو متغير عشوائي، فعندئذ الإجابة على تعيين توزيع المجموع S_n في العلاقة (*) ليس بسيطاً، ولكن المبرهنة الآتية (التي سيترك برهانها كتمرين للقارئ) تقدم لنا إحدى الطرائق المستخدمة في حساب توزيع S_n عندما تكون هذه المتغيرات العشوائية مستقلة ومتطابقة في التوزيع.

(٥, ٢, ٣, ٧) مبرهنة

إذا كانت $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية مستقلة فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ومتطابقة في التوزيع مع توزيع متغير عشوائي X فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ بدالة مولدة احتمالية G_X ، وليكن ζ متغيراً عشوائياً بقيم في \mathbb{N} ، ويملك دالة مولدة احتمالية G_ζ ، فإذا كان المتغير العشوائي ζ مستقل عن جميع المتغيرات العشوائية X_n من أجل كل $n \in \mathbb{N}$ ، فعندئذ يكون للمتغير العشوائي $Y = X_1 + X_2 + \dots + X_\zeta$ دالة مولدة احتمالية معطاة من خلال العلاقة الآتية:

$$G_Y(s) = G_\zeta(G_X(s)) \quad ; \forall s \in \mathbb{R} \quad [7,41]$$

(٦, ٢, ٣, ٧) ملاحظة

إن لهذه العلاقة الأخيرة أهمية كبيرة في التطبيقات، ولكن من الممكن أن تصبح مربكة (صعبة الحل) عندما تكون فيها الدوال G_ζ

و G_X مُركبة بشكل مُعقد، وستجنبها بوضع $P(\zeta = n) = 1$ ، فعندئذ سيكون من أجل كل $s \in \mathbb{R}$ لدينا ما يلي مُحققاً (سنقبل هذه النتائج دون برهان):

$$\text{a) } G_{\zeta}(s) = s^n \quad [7,42-a]$$

$$\text{b) } G_{S_n}(s) = (G_X(s))^n \quad [7,42-b]$$

والمثال الآتي يوضح لنا مدى أهمية المبرهنة السابقة في التطبيقات.

(٧, ٢, ٣, ٧) مثال

يرد إلى مركز صيانة للسيارات N سيارة في اليوم، علماً أن N يخضع لتوزيع بواسون بمعلمة $\lambda > 0$ ، ولنفترض أن كل سيارة يمكن إتمام صيانتها خلال اليوم نفسه باحتمال $0 < p < 1$ ، وأن عملية الصيانة للسيارات تتم بشكل مستقل بعضها عن بعضها الآخر، ولنفترض أيضاً أن X_k مع $N_N \ni k$ هو متغير عشوائي راصد للسيارة ذات الرقم k التي دخلت المركز في اليوم نفسه، فنجد أن X_1, X_2, \dots, X_N هي متغيرات عشوائية برنولية مستقلة بمعلمة p ، ومن ثم المتغير العشوائي $Y = X_1 + X_2 + \dots + X_N$ سيكون دالاً على عدد السيارات التي تم إصلاحها في اليوم نفسه، وهنا نلاحظ أنه لم يعد بإمكاننا أن ندعي أن Y توزيع حداني $B(N, p)$ لأن N أصبح متغيراً عشوائياً. لذلك سنستخدم الدراسة الأخيرة في تعيين توزيع المتغير العشوائي Y .

الحل: من معطيات المسألة لدينا الآتي:

$$G_N(s) = \sum_{k=0}^{\infty} s^k \frac{\lambda^k}{k!} e^{-\lambda} = \exp[\lambda(s-1)] \quad ; \forall s \in \mathbb{R}$$

ومن ثم يكون من أجل كل $N_N \ni k$ و $s \in \mathbb{R}$ لدينا ما يلي:

$$G_{X_k}(s) = (1-p) + ps = sp + (1-p) = p(s-1) + 1$$

وهكذا يصبح من أجل كل $N_N \ni k$ و $s \in \mathbb{R}$ لدينا الآتي مُحققاً:

$$G_Y(s) = G_N(G_{X_k}(s)) = \exp\{\lambda p \cdot (s-1)\}$$

وبمقارنتها مع G_N نجد أن G_Y هي الدالة المولدة الاحتمالية لمتغير عشوائي بواسوني بمعلمة $\lambda \cdot p$ ، ومن ثم سيكون للمتغير العشوائي Y توزيع بواسوني بمعلمة $\tilde{\lambda} = \lambda \cdot p$.

كتطبيق على هذا المثال سنفترض تحت الفرضيات الواردة آنفاً أنه يدخل إلى هذا المركز 100 سيارة في المتوسط، وأن احتمال إصلاح سيارة في اليوم نفسه يساوي 0.75، ولنحسب احتمال إصلاح 80 سيارة من السيارات التي دخلت هذا المركز في اليوم نفسه.

لدينا من معطيات المسألة $p = 0.75$ و $\lambda = EN = 100$ ، ولكن من أجل مسألتنا هذه لدينا علاوة على ما سبق ما يلي:

$$P(S_N = k) = \frac{(\lambda p)^k}{k!} e^{-\lambda p}$$

ومنه يكون الاحتمال المطلوب هو:

$$P(S_N = 80) = \frac{(75)^{80}}{(80)!} e^{-75} = 0.0379$$

أي إن احتمال إصلاح 80 سيارة من أصل 100 سيارة دخلت المركز في اليوم نفسه يساوي 0.0379.

(٧, ٣, ٣) الدالة المولدة لعزوم متغير عشوائي Moment Generating Function of a Random Variable

إن الدوال المولدة الاحتمالية مفيدة في دراسة المتغيرات العشوائية الصحيحة غير السالبة، ولكن من أجل متغيرات عشوائية أكثر عمومية يُفضل استخدام التحويل $s = e^t$ مع $t \in \mathbb{R}$ في صيغة الدالة المولدة للعزوم G_X فنحصل بذلك على ما يُسمى **بالدالة المولدة للعزوم** التي تمكّننا في كثير من الحالات من حساب العزوم الابتدائية للمتغيرات العشوائية من خلال اشتقاق دوالها، وهذا المفهوم الجديد يُقدّمه لنا التعريف الآتي.

(٧, ٣, ٣, ١) تعريف (الدالة المولدة لعزوم متغير عشوائي)

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، ولنعرّف من أجل هذا المتغير العشوائي دالة حقيقية M_X على \mathbb{R} من خلال العلاقة الآتية:

$$M_X : \mathbb{R} \longrightarrow \mathbb{R} ; t \mapsto M_X(t) = E e^{tX} \quad [7,43-a]$$

فعندئذ تُدعى M_X **الدالة المولدة لعزوم المتغير العشوائي** X .

(٧, ٣, ٣, ٢) ملاحظات

١- فإذا كان X متغيراً عشوائياً متقطعاً مجموعة قيمه $X = \{x_i ; i \in I\}$ ، فعندئذ يكون للدالة المولدة لعزوم X العرض الآتي:

$$M_X(t) = \sum_{i \in I} e^{tx_i} P(X = x_i) \quad ; t \in \mathbb{R} \quad [7,43-b]$$

وفي حال كانت مجموعة قيمه $X = \mathbb{N}$ ، فعندئذ سيصبح للدالة المولدة لعزوم X العرض الآتي:

$$M_X(t) = \sum_{k \in \mathbb{N}} e^{tk} P(X = k) \quad ; t \in \mathbb{R} \quad [7,43-c]$$

الآن، لكي يملك متغيراً عشوائياً X دالة مولدة للعزوم (**أي إن** M_X **موجودة**) يجب أن تكون أي من المتسلسلتين العدديتين السابقتين [7,43-b] و [7,43-c] متقاربة مطلقاً.

٢- إما إذا كان X متغيراً عشوائياً مستمراً بدالة كثافة احتمالية f_X ، فعندئذ يكون للدالة المولدة لعزوم X العرض الآتي:

$$M_X(t) = \int_{-\infty}^{+\infty} e^{tx} f_X(x) dx \quad ; t \in \mathbb{R} \quad [7,43-d]$$

ولكي يملك متغيراً عشوائياً X دالة مولدة للعزوم يجب أن يكون التكامل المعتل في العلاقة [7,43-d] متقارباً مطلقاً.

٣- نلاحظ الصلة الوطيدة بين M_X و **تحويل لابلاس** Laplace Transform، وذلك لأنّه لدينا:

$$M_X(t) = \int_{-\infty}^{+\infty} e^{tX} dF_X(x) \quad ; t \in \mathbb{R} \quad [7,44]$$

وإذا كان X مستمراً بدالة كثافة احتمالية f_X فعندئذ يصبح للعلاقة السابقة العرض الآتي:

$$M_X(t) = \int_{-\infty}^{+\infty} e^{tX} f_X(x) dx \quad ; t \in \mathbb{R}$$

٤- إن الدوال المولدة للعزوم تمتلك خصائص مماثلة لخصائص الدوال المولدة الاحتمالية (**لأنّها حالة خاصة من الدوال المولدة الاحتمالية عندما نأخذ** $s = e^t$)، فإذا كانت M_X موجودة على فترات مفتوحة تحوي نقطة الأصل (المبدأ)، فعندئذ:

أ- سيكون لدينا:

$$\mathbf{E} X^k = \mathbf{M}_X^{(k)}(0) \quad ; k \in \mathbb{N} \quad [7,45]$$

ب- سيكون لدينا من نشر تايلور Taylor's Expansion ما يلي:

$$\mathbf{M}_X(t) = \sum_{k=0}^{\infty} \frac{\mathbf{E} X^k}{k!} t^k \quad [7,46]$$

ج- إذا كان Y متغيراً عشوائياً فوق الفضاء الاحتمالي $[\Omega, \mathcal{A}, P]$ ومستقلاً عن X ، فعندئذ ينتج (إثباتها سيترك كتمرين) لدينا:

$$\mathbf{M}_{X+Y}(t) = \mathbf{M}_X(t) \cdot \mathbf{M}_Y(t) \quad ; t \in \mathbb{R} \quad [7,47]$$

وهذه النتيجة يمكن تعميمها على أي عدد من المتغيرات العشوائية المستقلة، فلو كانت لدينا X_1, X_2, \dots, X_n متغيرات عشوائية مستقلة فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ ستكون العلاقة الآتية محققة:

$$\mathbf{M}_{X_1+X_2+\dots+X_n}(t) = \prod_{k=1}^n \mathbf{M}_{X_k}(t) \quad ; t \in \mathbb{R} \quad [7,48]$$

أمثلة (٧, ٣, ٣, ٣)

١- لنأخذ $X \sim \mathbf{D}(c)$ متغيراً عشوائياً، فعندئذ يكون للدالة المولدة لعزوم X العرض الآتي:

$$\mathbf{M}_X(t) = e^{tc} \quad ; \forall t \in \mathbb{R}$$

وذلك لأنه من أجل كل $t \in \mathbb{R}$ لدينا:

$$\mathbf{M}_X(t) = \mathbf{E}_X(e^{tX}) = \sum_{i \in I} e^{tx_i} P(X = x_i) = e^{tc} \cdot P(X = c) = e^{tc}$$

فلاحظ أن الدالة المولدة لعزوم هذا المتغير العشوائي قابلة للاشتقاق على \mathbb{R} عدداً كبيراً من المرات، ومن ثم يمكننا حساب العزوم الابتدائية من مختلف المراتب لهذا المتغير العشوائي حيث لدينا من العلاقة [7,45] ما يلي:

$$\mathbf{E} X = \mathbf{M}_X^{(1)}(t) \Big|_{t=0} = (e^{tc})' \Big|_{t=0} = c e^{tc} \Big|_{t=0} = c$$

وبالمثل نجد أن العزوم الابتدائية من المرتبة الثانية لهذا المتغير العشوائي يساوي:

$$\mathbf{E} X^2 = \mathbf{M}_X^{(2)}(t) \Big|_{t=0} = (e^{tc})'' \Big|_{t=0} = c^2 e^{tc} \Big|_{t=0} = c^2$$

٢- لنأخذ $X \sim \mathbf{B}(n, p)$ متغيراً عشوائياً، فعندئذ يكون للدالة المولدة لعزوم X العرض الآتي:

$$\mathbf{M}_X(t) = [p(e^t - 1) + 1]^n \quad ; \forall t \in \mathbb{R}$$

وذلك لأنه من أجل كل $t \in \mathbb{R}$ لدينا:

$$\begin{aligned} \mathbf{M}_X(t) &= \mathbf{E}_X(e^{tX}) = \sum_{i \in I} e^{tx_i} P(X = x_i) = \sum_{k=0}^n e^{tk} P(X = k) = \sum_{k=0}^n e^{tk} \cdot \binom{n}{k} \cdot p^k \cdot (1-p)^{n-k} \\ &= \sum_{k=0}^n \binom{n}{k} \cdot (e^t p)^k \cdot (1-p)^{n-k} = [e^t p + (1-p)]^n = [p(e^t - 1) + 1]^n \end{aligned}$$

فلاحظ أن الدالة المولدة لعزوم هذا المتغير العشوائي قابلة للاشتقاق على \mathbb{R} عدداً كبيراً من المرات، ومن ثم يمكننا حساب العزوم

الابتدائية من مختلف المراتب لهذا المتغير العشوائي حيث لدينا من العلاقة [7,45] ما يلي:

$$\mathbf{E}X = \mathbf{M}_X^{(1)}(t) \Big|_{t=0} = \left(\left[p(e^t - 1) + 1 \right]^n \right)' \Big|_{t=0} = n p \left[p(e^t - 1) + 1 \right]^{n-1} \Big|_{t=0} = n p$$

وبالمثل نجد أن العزوم الابتدائية من المرتبة الثانية لهذا المتغير العشوائي يساوي:

$$\begin{aligned} \mathbf{E}X^2 = \mathbf{M}_X^{(2)}(t) \Big|_{t=0} &= \left(\left[p(e^t - 1) + 1 \right]^n \right)'' \Big|_{t=0} = \left(n p \left[p(e^t - 1) + 1 \right]^{n-1} \right)' \Big|_{t=0} \\ &= n(n-1)p^2 \left[p(e^t - 1) + 1 \right]^{n-2} \Big|_{t=0} = n(n-1)p^2 \end{aligned}$$

ومن ثم نجد باستخدام صيغة شتاينر أن التباين لهذا المتغير العشوائي يساوي:

$$\text{var } X = \mathbf{E}X^2 - (\mathbf{E}X)^2 = n(n-1)p^2 - (np)^2 = np(1-p)$$

لاحظ هنا السرعة والسهولة في حساب العزوم الابتدائية من المرتبة الأولى والثانية لهذا المتغير العشوائي مقارنة بما سبق وفقاً لاستخدام تعريف العزوم الابتدائية.

٣- لنأخذ $X \sim P(\lambda)$ متغيراً عشوائياً، فعندئذ يكون للدالة المولدة لعزوم X العرض الآتي:

$$\mathbf{M}_X(t) = \exp \{ \lambda(e^t - 1) \} \quad ; \forall t \in \mathbb{R}$$

وذلك لأنه من أجل كل $t \in \mathbb{R}$ لدينا:

$$\begin{aligned} \mathbf{M}_X(t) = \mathbf{E} e^{tX} &= \sum_{k=0}^{\infty} e^{tk} P(X=k) = \sum_{k=0}^{\infty} e^{tk} \frac{\lambda^k}{k!} e^{-\lambda} \\ &= e^{-\lambda} \sum_{k=0}^{\infty} \frac{(\lambda e^t)^k}{k!} = e^{-\lambda} e^{\lambda e^t} = \exp \{ \lambda(e^t - 1) \} \end{aligned}$$

وأما استنتاج العزوم الابتدائية من المرتبة الأولى والثانية لهذا المتغير العشوائي فيترك للقارئ.

٤- لنأخذ $X \sim U([a, b])$ متغيراً عشوائياً، فعندئذ يكون للدالة المولدة لعزوم X العرض الآتي:

$$\mathbf{M}_X(t) = \frac{e^{tb} - e^{ta}}{t(b-a)} \quad ; \forall t \in \mathbb{R}$$

وذلك لأنه من أجل كل $t \in \mathbb{R}$ لدينا:

$$\mathbf{M}_X(t) = \int_{-\infty}^{\infty} e^{tx} f_X(x) dx = \frac{1}{b-a} \int_a^b e^{tx} dx = \frac{1}{(b-a)} \frac{e^{tx}}{\ln e^t} \Big|_a^b = \frac{e^{tb} - e^{ta}}{t(b-a)}$$

وأما استنتاج العزوم الابتدائية من المرتبة الأولى والثانية لهذا المتغير العشوائي فيترك للقارئ.

٥- لنأخذ $X \sim \text{EX}(\lambda)$ متغيراً عشوائياً، فعندئذ يكون للدالة المولدة لعزوم X العرض الآتي:

$$\mathbf{M}_X(t) = \frac{\lambda}{\lambda - t} \quad ; \forall t \in \mathbb{R}$$

وذلك لأنه من أجل كل $t \in \mathbb{R}$ لدينا:

$$\begin{aligned} M_X(t) &= \int_{-\infty}^{\infty} e^{tx} f_X(x) dx = \int_{-\infty}^{\infty} e^{tx} \lambda e^{-\lambda x} I_{[0,\infty)}(x) dx = \lambda \int_0^{\infty} e^{tx} e^{-\lambda x} dx \\ &= \lambda \int_0^{\infty} e^{-x(\lambda-t)} dx = \frac{\lambda}{-(\lambda-t)} e^{-x(\lambda-t)} \Big|_0^{\infty} = \frac{\lambda}{\lambda-t} \end{aligned}$$

وأما استنتاج العزوم الابتدائية من المرتبة الأولى والثانية لهذا المتغير العشوائي فيترك للقارئ.

(٧,٤) الدوال المميزة للتوزيعات الاحتمالية

Characteristic Function of Probability Distributions

لقد أثبتت الدراسات أن الدوال المميزة لدوال التوزيع الاحتمالية لها شأن كبير جداً في مجال الدراسات التحليلية لنظرية الاحتمالات، لا بل أكثر من ذلك، يمكن اشتقاق الكثير من المبرهنات المهمة في مجال الطرائق التحليلية لنظرية الاحتمالات بوساطة الدوال المميزة، ولذلك لجئ إلى استخدام هذا النوع من الدوال في حل العديد من القضايا المتعلقة بهذه النظرية، وعلى وجه الخصوص تلك القضايا التي تهتم بتوليد العزوم للمتغيرات العشوائية. علاوة على ما سبق، من النتائج المهمة والرئيسية للدراسات التحليلية لنظرية الاحتمالات الموضوعات الآتية:

- نظريات الوحدةانية Uniqueness theorem's.

- نظريات العكس Inversion theorem's.

- نظريات التلاف Convolution theorem's.

- نظريات الاستمرار Continuity theorem's.

- نظريات النهاية المركزية Central limit theorem's.

إن هذه الدراسات تسمح لنا باستبدال الدراسة على دالة توزيع احتمالية باستقصاء مكافئ لدوال مميزة مقابلة لها، وكذلك نجد أن الدوال المميزة للمتغيرات العشوائية تمكننا من تعيين التوزيعات التي لا تملك عزوماً ابتدائية أيضاً.

(٧,٤,١) الدالة المميزة لتوزيع احتمالي Characteristic Function of Probability Distribution

سنقوم فيما يلي بتقديم تعريف المتغير العشوائي العقدي أولاً، ومن ثم تعريف الدالة المميزة لدالة توزيع احتمالية، ونستخلص منها الدالة المميزة لمتغير عشوائي، علماً أن دراستنا التالية ستكون مركزة على الدوال المميزة للمتغيرات العشوائية.

(٧,٤,١,١) تعريف (المتغير العشوائي العقدي Complex Random Variable)

ليكن X و Y متغيرين عشوائيين فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ يدعى المتغير العشوائي:

$$Z := X + iY \quad [7,49]$$

متغيراً عشوائياً عقدياً (أو مركباً). علماً أن i هو العدد العقدي الممثل بالنقطة $(0,1)$ في المستوى العقدي، والمميز بالعلاقة $i^2 = -1$.

من الواضح هنا أنه يكون لهذا المتغير العشوائي توقع رياضيائي إذا وفقط إذا كان $E|X| < +\infty$ وكذلك $E|Y| < +\infty$ ، وفي هذه الحالة يكون لدينا:

$$EZ = EX + i \cdot EY \quad [7,50]$$

إن الخصائص المتعلقة بالتوقع الرياضيائي للمتغيرات العشوائية الحقيقية تبقى سارية المفعول من أجل المتغيرات العشوائية العقدية مع الانتباه لدى التعامل مع المتباينات، وذلك لأنه يجب أخذ طويلة المتغير العشوائي العقدي في هذه الحالة.

تعريف (٧, ٤, ١, ٢) الدالة المميزة لدالة توزيع احتمالية) Characteristic Function of Distribution Function

لتكن F دالة توزيع احتمالية، ولنعرّف من أجلها دالة عقدية φ_F على \mathbb{R} من خلال العلاقة الآتية:

$$\varphi_F : \mathbb{R} \longrightarrow \mathbb{C} \quad ; t \mapsto \varphi_F(t) := \int_{-\infty}^{\infty} e^{itx} dF(x) \quad [7,51]$$

عندئذ تدعى φ_F **الدالة المميزة** للدالة F .

(٧, ٤, ١, ٣) ملاحظات

١- نلاحظ هنا أنّ التكامل المقدم في العلاقة [7,51] هو من نوع تكاملات ريمان-ستلجس المعتلة، وهذا التكامل موجود من أجل كل دالة توزيع احتمالية F لأنّ $|e^{itx}| = 1$.

٢- إذا كانت F_X دالة توزيع متغير عشوائي X فعندئذ سنكتب φ_X عوضاً عن φ_{F_X} ، ونجد أنّ التكامل الذي في الطرف الأيمن للعلاقة [7,51] هو التوقع الرياضي للمتغير العشوائي العقدي e^{itX} ، ومن ثمّ يمكننا أن نكتب الآتي:

$$\varphi_X(t) = E e^{itX} \quad ; \forall t \in \mathbb{R} \quad [7,52]$$

وهذه الدالة φ_X تدعى **الدالة المميزة للمتغير العشوائي** X .

٣- إنّ الدوال المميزة للمتغيرات العشوائية ذات صلة وطيدة بـ **تحويل فورييه** Fourier Translation، وذلك لأنّ التكامل الذي في الطرف الأيمن من العلاقة [7,51] يمثل تحويل فورييه -ستلجس Fourier-Stieltjes Translation، وأما التكامل:

$$F(t) = \int_{-\infty}^{\infty} e^{-itx} f(x) dx$$

فإنّه يمثل تحويل فورييه التكاملي للدالة $f(x)$ ، في حين أنّ التكامل:

$$f(x) = \frac{1}{2\pi} \int_{-\infty}^{\infty} e^{itx} F(t) dt$$

هو تحويل فورييه العكسي.

٤- من أجل كل $t \in \mathbb{R}$ يمكن عرض الدالة φ_F كما في العلاقة الآتية:

$$\varphi_F(t) = \int_{-\infty}^{\infty} \cos tx dF(x) + i \int_{-\infty}^{\infty} \sin tx dF(x) \quad ; \forall t \in \mathbb{R} \quad [7,53]$$

ومن العلاقة الأخيرة [7,53] نستنتج أنّ الدالة المميزة φ_F موجودة في جوار المبدأ من أجل كل دالة توزيع احتمالية F ، وإذا كانت الدالة F هي دالة توزيع متغير عشوائي X ، فعندئذ سيكون لدينا:

$$\varphi_X(t) = E(\cos tX) + i E(\sin tX) \quad [7,54]$$

(٧, ٤, ٢) خصائص الدالة المميزة لتوزيع احتمالي

تقدّم لنا المبرهنة الآتية بعض الخصائص المهمة للدوال المميزة للمتغيرات العشوائية.

(٧, ٤, ٢, ١) مبرهنة

لتكن φ_X دالة مميزة لمتغير عشوائي X فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ بدالة توزيع احتمالية F_X ، فعندئذ ينتج لدينا من التعريف أنّ $\varphi_X(0) = E(1) = 1$ ، وكذلك من أجل كل $t \in \mathbb{R}$ يكون لهذه الدالة الخصائص الآتية:

١- لدينا:

$$\text{a) } |\varphi_X(t)| \leq 1 \quad \& \quad \text{b) } \varphi_X(-t) = \overline{\varphi_X(t)}$$

٢- الدالة φ_X موجبة التعيين Positive Definite، والتي تعني أنه من أجل كل $N_n \ni i$ وأية قيم $C \ni z_i$ و $R \ni t_i$ لدينا العلاقة الآتية مُحَقَّقة:

$$\sum_{j=1}^n \sum_{k=1}^n \varphi_X(t_j - t_k) z_j \bar{z}_k \geq 0 \quad [7,55]$$

البرهان: من أجل الفقرة (١) نلاحظ وضوحاً أنه من أجل كل $R \ni t$ لدينا الآتي مُحَقَّقاً:

$$|\varphi_X(t)| \leq \int_{\mathbb{R}} |e^{itx}| dF_X(t) = \int_{\mathbb{R}} dF_X(t) = 1$$

وأخيراً من أجل كل $R \ni t$ لدينا:

$$\varphi_X(-t) = \int_{\mathbb{R}} e^{-itx} dF_X(t) = \int_{-\infty}^{\infty} \cos tx dF_X(x) - i \int_{-\infty}^{\infty} \sin tx dF_X(x) = \overline{\varphi_X(t)}$$

٢- من أجل الفقرة (٢) نجد من أجل كل $N_n \ni i$ وأية قيم $C \ni z_i$ و $R \ni t_i$ ما يلي مُحَقَّقاً:

$$\sum_{j=1}^n \sum_{k=1}^n \varphi_X(t_j - t_k) z_j \bar{z}_k = \sum_{j=1}^n \sum_{k=1}^n \int_{\mathbb{R}} z_j e^{it_j x} \bar{z}_k e^{-it_k x} dF_X(x) = \mathbf{E} \left| \sum_{j \in N_n} z_j \exp(i t_j x) \right|^2 \geq 0$$

وبهذا يتم البرهان.

تظهر لنا المبرهنة الآتية (التي سنقدمها دون برهان لأنها تمثل مبرهنة تايلور من أجل الدوال العقدية) بعض الخصائص الإضافية للدوال المميزة للمتغيرات العشوائية.

(٧, ٤, ٢, ٢) مبرهنة

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ:

١- إذا كان المقدار $\varphi_X^{(k)}(0)$ موجوداً فإنه:

أ- إذا كان k عدداً زوجياً، فإنه سيكون لدينا $\mathbf{E} |X^k| < +\infty$.

ب- إذا كان k عدداً فردياً، فإنه سيكون لدينا $\mathbf{E} |X^{k-1}| < +\infty$.

٢- إذا كان $\mathbf{E} |X^k| < +\infty$ ، فعندئذ من أجل كل $R \ni t$ يكون لدينا:

$$\varphi_X(t) = \sum_{j=0}^k \frac{\mathbf{E} X^j}{j!} (it)^j + \theta(t^k) \quad [7,56]$$

علماً أن $\lim_{t \rightarrow 0} \theta(t^k) = 0$.

(٧, ٤, ٢, ٣) نتيجة

من المبرهنة السابقة نستنتج تحت الفرض أنه من أجل $N \ni k$ لدينا $\mathbf{E} |X^k| < +\infty$ ، فعندئذ سينتج لدينا أن:

$$\varphi_X^{(k)}(0) = i^k \cdot \mathbf{E} X^k \quad [7,57]$$

وهذه العلاقة الأخيرة تساعدنا في حساب لنا العزوم الابتدائية حتى المرتبة k للمتغير العشوائي X بوساطة الاشتقاق للدالة φ_X .

قبل ختام فقرة الدوال المميزة للمتغيرات العشوائية سنقدم مبرهنتين تعرضان لنا بعض الخصائص الإضافية التي تتمتع بها هذه الدوال.

(٧, ٤, ٢, ٤) مبرهنة

ليكن X و Y متغيرين عشوائيين فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ:

١- إذا كان $Z = aX + b$ مع $a \in \mathbb{R}$ و $a \neq 0$ فإنه سيكون لدينا:

$$\varphi_Z(t) = e^{itb} \cdot \varphi_X(at) \quad ; \forall t \in \mathbb{R} \quad [7,58]$$

٢- إذا كان Y مستقلاً عن X ، فعندئذ يكون لدينا:

$$\varphi_{X+Y}(t) = \varphi_X(t) \cdot \varphi_Y(t) \quad ; \forall t \in \mathbb{R} \quad [7,59-a]$$

البرهان: لإثبات صحة الفقرة (١) لدينا من أجل $t \in \mathbb{R}$ ما يلي:

$$\varphi_Z(t) = E e^{it(aX+b)} = E \left(e^{itb} \cdot e^{iatX} \right) = e^{itb} \cdot E e^{i(at)X} = e^{itb} \cdot \varphi_X(at)$$

وأما لإثبات صحة الفقرة (٢) فإنه بسبب استقلال Y عن X سيكون من أجل كل $t \in \mathbb{R}$ لدينا ما يلي:

$$\varphi_{X+Y}(t) = E e^{it(X+Y)} = E \left(e^{itX} \cdot e^{itY} \right) \stackrel{\text{من استقلال } X \text{ و } Y}{=} E e^{itX} \cdot E e^{itY} = \varphi_X(t) \cdot \varphi_Y(t)$$

وبهذا يتم المطلوب.

(٧, ٤, ٢, ٥) ملاحظات

١- إن البند الثاني من المبرهنة السابقة يمكن تعميمها على أي عدد من المتغيرات العشوائية المستقلة (إثباتها سيترك كتمرين

للقارئ)، أي إنه إذا كانت X_1, X_2, \dots, X_n متغيرات عشوائية مستقلة فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ من أجل كل $t \in \mathbb{R}$ ستكون العلاقة الآتية محققة:

$$\varphi_{X_1+X_2+\dots+X_n}(t) = \prod_{k=1}^n \varphi_{X_k}(t) \quad [7,59-b]$$

٢- يجب الانتباه لدى حساب التكاملات في مسائل تتعلق بالدوال المميزة؛ وذلك لأننا نتعامل مع تكاملات عقدية (ليست حقيقية)، ومن ثم يجب الانتباه لوضع النقطة (0,1) الممثلة للعدد العقدي i بالنسبة للقطاع المكامل عليه.

(٧, ٤, ٢, ٦) أمثلة

١- ليكن $X \sim B(p)$ ، فعندئذ نجد من أجل كل $t \in \mathbb{R}$ ما يلي:

$$\varphi_X(t) = E e^{itX} = \sum_{k=0}^1 e^{itk} P(X=k) = (1-p) + p e^{it}$$

٢- ليكن $X \sim B(n, p)$ ، فعندئذ، وكما أوضحنا سابقاً، يمكن أخذ توزيع هذا المتغير العشوائي كتوزيع مجموع n متغير

عشوائي برنولي مستقل Y_1, Y_2, \dots, Y_n ، ومن ثم يكون من أجل كل $t \in \mathbb{R}$ لدينا ما يلي محققاً:

$$\varphi_X(t) = \varphi_{Y_1+Y_2+\dots+Y_n}(t) = \varphi_{Y_1}(t) \cdot \varphi_{Y_2}(t) \cdot \dots \cdot \varphi_{Y_n}(t) = \left[(1-p) + p e^{it} \right]^n$$

٣- ليكن $X \sim \text{EX}(\lambda)$ ، فعندئذ سيكون لدينا $\varphi_X(t) = \frac{\lambda}{\lambda - it}$ من أجل كل $t \in \mathbb{R}$ ، وذلك لأنه من أجل كل $t \in \mathbb{R}$ لدينا ما يلي:

$$\begin{aligned}\varphi_X(t) &= \mathbb{E} e^{itX} = \int_{-\infty}^{\infty} \lambda e^{itx} e^{-\lambda x} \mathbf{I}_{[0, \infty)}(x) dx = \lambda \int_0^{\infty} e^{-\lambda x} (\cos tx + i \sin tx) dx \\ &= \lambda \left[\int_0^{\infty} e^{-\lambda x} \cos tx dx + i \int_0^{\infty} e^{-\lambda x} \sin tx dx \right]\end{aligned}$$

والتي نجد منها أن:

$$\varphi_X(t) = \mathbb{E} e^{itX} = \frac{\lambda^2}{\lambda^2 + t^2} + i \frac{\lambda t}{\lambda^2 + t^2} = \frac{\lambda}{\lambda - it}$$

٤- ليكن $X \sim \text{N}(\mu, \sigma)$ ، فعندئذ سيكون لدينا $\varphi_X(t) = e^{i\mu t - \frac{1}{2}\sigma^2 t^2}$ من أجل كل $t \in \mathbb{R}$ ، ولإثبات ذلك سنأخذ Y متغيراً عشوائياً خاضعاً للتوزيع الطبيعي المعياري $Y \sim \text{N}(0, 1)$ ، فعندئذ من أجل كل $t \in \mathbb{R}$ يكون لدينا ما يلي:


$$\varphi_Y(t) = \mathbb{E} e^{itY} = \int_{-\infty}^{\infty} e^{ity} \cdot \frac{1}{\sqrt{2\pi}} e^{-\frac{y^2}{2}} dy = \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left(it y - \frac{y^2}{2}\right) dy$$

وبحساب هذا التكامل الأخير نجد أن:

$$\varphi_Y(t) = e^{-\frac{t^2}{2}} \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-\frac{(y-it)^2}{2}} e^{-\frac{t^2}{2}} dy = e^{-\frac{t^2}{2}} \quad ; \forall t \in \mathbb{R}$$

وبأخذ $X = \sigma Y + \mu$ ، واستخدام خواص الدالة المميزة، نجد الآتي:

$$\varphi_X(t) = \varphi_{\sigma Y + \mu}(t) = e^{it\mu} \varphi_Y(\sigma t) = e^{it\mu} \cdot e^{-\frac{1}{2}\sigma^2 t^2} = e^{i\mu t - \frac{1}{2}\sigma^2 t^2}$$



في الواقع كان من الممكن الوصول إلى النتيجة السابقة نفسها من خلال حساب التكامل الآتي:

$$\varphi_X(t) = \mathbb{E} e^{itX} = \int_{-\infty}^{\infty} e^{itx} \cdot \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx \quad ; \forall t \in \mathbb{R}$$

وذلك على المسار المغلق ABCD الذي يحيط بالنقطة $i = (0, 1)$ (انظر الشكل الجانبي).

(٣، ٤، ٧) نظريات شهيرة في دراسة الدوال المميزة

النظريات الآتية (التي سنقبلها دون برهان) تُعدّ من النظريات المهمة في إطار دراسة الدوال المميزة للمتغيرات العشوائية. إن أول هذه النظريات تعطينا الشرط اللازم والكافي حتى تكون دالة عقدية معرفة على \mathbb{R} هي دالة مميزة لمتغير عشوائي، وتعرف هذه النظرية باسم **نظرية بوخنر** نسبة إلى الرياضي الأمريكي (هنغاري الأصل) **بوخنر** (Salomon Bochner (1899-1982).

(١، ٣، ٤، ٧) نظرية بوخنر Bochner Theorem

إن الشرط اللازم والكافي حتى تكون دالة عقدية φ معرفة على \mathbb{R} هي دالة مميزة لمتغير عشوائي X هو أن تتحقق البنود الآتية:

١- من أجل كل $t \in \mathbb{R}$ لدينا $|\varphi(t)| \geq 1$.

٢- الدالة $\varphi(t)$ مستمرة بانتظام على \mathbb{R} .

٣- من أجل أية قيم حقيقية كل t_1, t_2, \dots, t_n من \mathbb{R} ، و أية قيم عقدية z_1, z_2, \dots, z_n من \mathbb{C} لدينا:

$$\sum_{j,k=1}^n \varphi(t_j - t_k) z_j \bar{z}_k \geq 0 \quad [7,60]$$

وهذا البند الأخير يعني أن الدالة $\varphi(t)$ غير سالبة التعيين.

من المسائل المهمة أيضاً في نظرية الاحتمالات وتطبيقاتها (في نظرية المعاينة) موضوع حساب قيم التوزيع لمتغير عشوائي باستخدام الدالة المميزة له، وهذا ما تقدمه لنا النظرية الآتية (سنقبلها دون برهان) والتي تعود إلى الرياضياتي الفرنسي ليفي Paul Pierre Lévy (1886-1971) التي قدمها عام 1925.

(٢, ٣, ٤, ٧) نظرية ليفي Lévy Theorem

لتكن X متغير عشوائي فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، ولنفترض أن φ_X و F_X هما الدالة المميزة ودالة التوزيع لمتغير عشوائي X على الترتيب. فإذا كانت الدالة F_X مستمرة في جوار نقطة $x_0 \in \mathbb{R}$ فإنه من أجل أي $0 < \varepsilon$ ستكون العلاقة الآتية محققة:

$$F_X(x_0 + \varepsilon) - F_X(x_0 - \varepsilon) = \lim_{A \rightarrow \infty} \frac{1}{\pi} \int_{-A}^A \frac{\sin \varepsilon t}{t} e^{itx_0} \varphi_X(t) dt \quad [7,61]$$

وأكثر من ذلك، فإذا كان $\int_{-\infty}^{\infty} |\varphi_X(t)| dt < +\infty$ فإن دالة الكثافة الاحتمالية f_X ستكون موجودة في النقطة x_0 وتُعطى بالعلاقة الآتية:

$$f_X(x_0) = \frac{1}{2\pi} \int_{-\infty}^{\infty} e^{-itx_0} \varphi_X(t) dt \quad [7,62]$$

لاحظ أن هذه المبرهنة تظهر لنا وجود تقابل واحد لواحد بين دوال التوزيع الاحتمالية للمتغيرات العشوائية وبين الدوال المميزة لها، ولذلك تُعرف هذه النتيجة في الاحتمالات باسم **نظرية الوجدانية**.

أخيراً سنقدم إحدى المبرهنات الأخرى المتعلقة بالدوال المميزة للمتغيرات العشوائية والتي تُعرف باسم **نظرية الاستمرار لـ ليفي** (وسنقبلها دون برهان أيضاً).

(٣, ٣, ٤, ٧) نظرية الاستمرار لـ ليفي Lévy's Continuity Theorem

لتكن $X_1, X_2, \dots, X_n, \dots$ متتالية متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ بدوال توزيع احتمالية $F_{X_1}, F_{X_2}, \dots, F_{X_n}, \dots$ ودوال مميزة $\varphi_{X_1}, \varphi_{X_2}, \dots, \varphi_{X_n}, \dots$ على الترتيب، فعندئذ:

١- إذا كانت المتتالية $(F_{X_n})_{n \in \mathbb{N}}$ متقاربة من دالة توزيع احتمالية F_X لمتغير عشوائي ما X فوق $[\Omega, \mathcal{A}, P]$ ، فإنه سيكون لدينا ما يلي محققاً:

$$\lim_{n \rightarrow \infty} \varphi_{X_n}(t) = \varphi_X(t) \quad ; \forall t \in \mathbb{R}$$

٢- إذا كانت المتتالية $(\varphi_{X_n})_{n \in \mathbb{N}}$ متقاربة من دالة مميزة φ_X لمتغير عشوائي ما X فوق $[\Omega, \mathcal{A}, P]$ ، وكانت هذه الدالة مستمرة في النقطة $t = 0$ ، فإنه سيكون لدينا ما يلي محققاً:

$$\lim_{n \rightarrow \infty} F_{X_n}(x) = F_X(x) \quad ; \forall x \in \mathbb{R}$$

وذلك من أجل كل نقطة استمرار x للدالة F_X .

(٧,٥) التوقع الشرطي**Conditional Expectation**

إنَّ التوقع الشرطي يُعدُّ من المفاهيم الضرورية في مجال العشوائيات لأنَّ مسائل عديدة تؤوّل في دراستها إلى موضوع التوقع الشرطي، لا بل أكثر من ذلك توجد قطاعات بحثية عديدة في نظرية الاحتمالات تقوم على مفهوم التوقع الشرطي بشكل أساسي ومنها على سبيل المثال لا الحصر **نظرية الحَكَمَة** Martingale Theorem. إنَّ كلمة Martingale فرنسية تعني "**الحَكَمَة**" وهي حديدة اللجام التي تكون في فم الفرس لإحكام جماعه، وسميت هذه النظرية بهذا الاسم لأنَّها بنيت في البدايات على رهانات سباق الخيل، ومدى تأثير الحَكَمَة على نتائج السباق.

سنقوم فيما يلي بتوضيح مفهوم التوقع الشرطي، ولكن على سبيل التوضيح والتبسيط سنقوم بشرح لهذا المفهوم من أجل الحالة الخاصة التي يكون فيها فضاء الحوادث الابتدائية Ω منتهياً، وكذلك المتغيرات العشوائية المستخدمة في هذه الدراسة هي متغيرات عشوائية متقطعة، ومن ثمَّ نعرض أهمَّ خصائص التوقع الشرطي من أجل هذه الحالة الخاصة.

ليكن $[\Omega, \mathcal{A}, P]$ فضاءً احتمالياً معطى بحيث تكون Ω منتهية، ولناخذ $\mathcal{Z} = \{Z_i \subseteq \Omega ; i \in \mathbb{N}_k\}$ تجزئة لفضاء الحوادث الابتدائية Ω . عندئذ سنقوم بتعريف التوقع الشرطي وفقاً للمنهج الآتي:

أولاً: تعريف التوقع الشرطي لحادث A بالنسبة إلى التجزئة \mathcal{Z} .

ثانياً: تعريف التوقع الشرطي لمتغير عشوائي X بالنسبة إلى التجزئة \mathcal{Z} .

(٧,٥,١) التوقع الشرطي لحادث A بالنسبة إلى تجزئة \mathcal{Z}

فيما يلي سنقوم بتوضيح مفهوم التوقع الشرطي لحادث A بالنسبة إلى تجزئة \mathcal{Z} ونبدأ ذلك بالتعريف الآتي.

(٧,٥,١,١) تعريف (التوقع الشرطي لحادث A بالنسبة إلى تجزئة \mathcal{Z})

ليكن $P(A | Z_i)$ هو الاحتمال الشرطي لحادث $A \in \mathcal{A}$ بالنسبة إلى ذرة التجزئة Z_i ، فعندئذ يمكننا من خلال الاحتمالات الشرطية $\{P(A | Z_i) ; i \in \mathbb{N}_k\}$ أن نولّد متغيراً عشوائياً X_o فوق $[\Omega, \mathcal{A}, P]$ وفقاً للعلاقة الآتية:

$$X_o(\omega) := \sum_{i=1}^k P(A | Z_i) \cdot \mathbf{I}_{Z_i}(\omega) \quad [7,63]$$

وبهذا الشكل نلاحظ أنَّ كلَّ تجزئة لـ Ω يوافقها متغير عشوائي يُعرّف وفقاً للعلاقة [7,63]، وأكثر من ذلك نلاحظ من هذه العلاقة الأخيرة أنَّ قيم X_o على ذرات التجزئة Z_i هي $P(A | Z_i)$ (مقادير ثابتة) من أجل كلِّ $i \in \mathbb{N}_k$ ، ولكي نميِّز العلاقة الخاصة بالمتغير العشوائي X مع التجزئة \mathcal{Z} سوف نكتب:

$$X_o(\omega) \triangleq P(A | \mathcal{Z})(\omega) \quad ; \forall \omega \in \Omega \quad [7,64]$$

علماً أنَّ العلاقة السابقة تُدعى **الاحتمال الشرطي للحدث $A \in \mathcal{A}$ بالنسبة إلى التجزئة \mathcal{Z}** .

(٧,٥,١,٢) خصائص الاحتمال الشرطي بالنسبة إلى تجزئة

١- من أجل أي حادّين متنافيين $A, B \in \mathcal{A}$ تكون العلاقة الآتية مُحَقَّقة:

$$P(A + B | \mathcal{Z}) = P(A | \mathcal{Z}) + P(B | \mathcal{Z}) \quad [7,65]$$

٢- في الحالة الخاصة إذا كانت \mathcal{Z} هي التجزئة المبتذلة (أي إنَّ $\mathcal{Z} = \{\Omega\}$)، فعندئذ ستكون العلاقة الآتية مُحَقَّقة:

$$P(A | \mathcal{Z}) + P(A) \quad [7,66]$$

وذلك لأن $I_{\Omega}(\omega) = 1$ من أجل كل $\omega \in \Omega$ ، ومن ثم يكون لدينا:

$$P(A | \mathcal{Z})(\omega) = \sum_{i=1}^k P(A | Z_i) \cdot I_{Z_i}(\omega) = P(A | \Omega) \cdot I_{\Omega}(\omega) = P(A | \Omega) = \frac{P(A \cap \Omega)}{P(\Omega)} = P(A)$$

لاحظ أن تعريف الاحتمال الشرطي لحادث بالنسبة إلى تجزئة كمتغير عشوائي يعطينا إمكانية في التحدث عن قيمته المتوقعة، ومن ثم يمكننا استغلال هذا الطرح من أجل تقديم صيغة الاحتمال التام، ويتم ذلك على النحو الآتي:

ليكن $A \in \mathcal{A}$ كفيماً، فعندئذ يمكننا أن نكتب الآتي (صيغة الاحتمال التام):

$$P(A) = E[P(A | \mathcal{Z})] \quad [7,67]$$

وذلك لأنه من تعريف X_o يمكننا أن نكتب الآتي:

$$E[X_o(\omega)] = E[P(A | \mathcal{Z})](\omega) = \sum_{i=1}^k P(A | Z_i) \cdot E[I_{Z_i}(\omega)]$$

ولكن نعلم أن $E[I_{Z_i}(\omega)] = P(Z_i)$ ، ومن ثم يصبح لدينا:

$$E[P(A | \mathcal{Z})](\omega) = \sum_{i=1}^k P(A \cap Z_i) = P(A)$$

وبهذا نكون قد حصلنا على صيغة الاحتمال التام.

لنقم الآن بتعريف التجزئة المولدة من متغير عشوائي على النحو الآتي.

(٧, ٥, ١, ٣) تعريف (التجزئة المولدة من متغير عشوائي The Generated Partition by a Random Variable)

ليكن Y متغيراً عشوائياً متقطعاً فوق $[\Omega, \mathcal{A}, P]$ بمجموعة قيم $Y = \{y_j ; j \in \mathbb{N}_k\}$ واحتمالات $P(Y = y_j) > 0$ من أجل كل $j \in \mathbb{N}_k$ ، ومعرفةً بالعلاقة الآتية:

$$Y(\omega) := \sum_{j=1}^k y_j \cdot I_{Z_j}(\omega) \quad [7,68]$$

وبملاحظة أن Y يأخذ قيمة ثابتة على الذرات Z_j ، فإنه سيكون لهذه الذرات العرض الآتي:

$$Z_j = \{\omega \in \Omega ; Y(\omega) = y_j\} \quad ; j \in \mathbb{N}_k \quad [7,69]$$

إن التجزئة \mathcal{Z} التي ذراتها معطاة وفقاً للعلاقة [7,69] تُسمى **التجزئة المولدة بـ Y** ويرمز لها بـ \mathcal{Z}_Y أي إنه لدينا:

$$\mathcal{Z}_Y = \{Z_j : Z_j = \{\omega \in \Omega ; Y(\omega) = y_j\} ; \forall j \in \mathbb{N}_k\} \quad [7,70]$$

(٧, ٥, ١, ٤) ملاحظات

١- يُشار عادة إلى الاحتمال الشرطي $P(A | \mathcal{Z}_Y)$ بالرمز $P(A | Y)$ أو بالشكل $P(A | Y)(\omega)$ لبيان أنه متغير عشوائي، ويُقال له الاحتمال الشرطي للحادث A بالنسبة إلى المتغير العشوائي Y .

٢- سنتفق على أن الكتابة $P(A | Y = y_j)$ تعني الاحتمال الشرطي $P(A | Z_j)$ علماً أن Z_j معطاة وفقاً للعلاقة [7,69] من أجل كل $j \in \mathbb{N}_k$.

٣- إن المتغير العشوائي $P(A | \mathcal{Z}_Y)$ قياساً بالنسبة إلى σ -جبر $\mathcal{Z} = \sigma(\mathcal{Z})$ (ال- σ -جبر المولّد من التجزئة \mathcal{Z})، ولذلك يُرمز له بـ $P(A | \mathcal{S})$ أيضاً.

بهذا الشكل يكون مفهوم الاحتمال الشرطي لحادث بالنسبة إلى σ -جبر مبرراً وله معنى.

(٧, ٥, ١, ٥) تعريف (التجزئة المولدة من عدد منته من المتغيرات العشوائية)

ليكن Y_1, Y_2, \dots, Y_m متغيرات عشوائية متقطعة فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، وسنفترض أن مجموعات قيمها على الترتيب هي $Y_\ell = (y_{\ell k_s}; s \in \mathbb{N}_{n_\ell})$ من أجل كل $\ell \in \mathbb{N}_m$ ، وكذلك سنفترض أن:

$$P(Y_\ell = y_{\ell k_s}) > 0 \quad ; s \in \mathbb{N}_{n_\ell}, \ell \in \mathbb{N}_m \quad [7,71]$$

ولنعرف المجموعات الآتية:

$$Z_{y_{1k_1}, y_{2k_2}, \dots, y_{mk_m}} := \left(\omega \in \Omega : Y_\ell(\omega) = y_{\ell k_\ell} ; k_\ell \in \mathbb{N}_{n_\ell}, \ell \in \mathbb{N}_m \right) \quad [7,72]$$

عندئذ تدعى أسرة الحوادث (المجموعات):

$$\mathcal{Z}_{Y_1, Y_2, \dots, Y_m} := \left(Z_{y_{1k_1}, y_{2k_2}, \dots, y_{mk_m}} ; \forall k_\ell \in \mathbb{N}_{n_\ell}, \ell \in \mathbb{N}_m \right)$$

التجزئة المولدة من المتغيرات العشوائية Y_1, Y_2, \dots, Y_m .

(٧, ٥, ١, ٦) ملاحظات

١- يُشار عادة إلى الاحتمال الشرطي $P(A | \mathcal{Z}_{Y_1}, \mathcal{Z}_{Y_2}, \dots, \mathcal{Z}_{Y_m})$ بالرمز $P(A | Y_1, Y_2, \dots, Y_m)(\omega)$ لتبيان أنه متغير عشوائي، ويدعى الاحتمال الشرطي للحدث A بالنسبة إلى المتغيرات العشوائية Y_1, Y_2, \dots, Y_m .

٢- سنتفق على أن الاصطلاح الآتي:

$$P\left(A | Z_{y_{1k_1}, y_{2k_2}, \dots, y_{mk_m}}\right) \triangleq P\left(A | Y_1 = y_{1k_1}, Y_2 = y_{2k_2}, \dots, Y_m = y_{mk_m}\right)$$

علماً أن المجموعة $Z_{y_{1k_1}, y_{2k_2}, \dots, y_{mk_m}}$ مُعطاة وفقاً للعلاقة [7,72].

(٧, ٥, ٢) التوقع الشرطي لمتغير عشوائي بالنسبة إلى تجزئة

The Conditional Expectation of a R.V. with respect to a Partition

سنقوم بتوضيح مفهوم التوقع الشرطي لمتغير عشوائي X بالنسبة إلى تجزئة \mathcal{Z} مُعطاة.

(٧, ٥, ٢, ١) تعريف (التوقع الشرطي لمتغير عشوائي بالنسبة إلى تجزئة)

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ بمجموعة قيم $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$ (أي إن X متغير عشوائي بسيط)، فعندئذ يمكن عرضه على النحو الآتي:

$$X = \sum_{i=1}^n x_i \mathbf{I}_{A_i} \quad ; \forall i \in \mathbb{N}_n$$

علماً أنَّ الحوادث A_i لها العرض الآتي:

$$A_i = \{\omega \in \Omega ; X(\omega) = x_i\} \quad ; \forall i \in \mathbb{N}_n$$

ومن ثم نجد أنَّ التوقع الرياضي لـ X يساوي:

$$\mathbf{E} X = \sum_{i=1}^n x_i \cdot P(A_i) \quad [7,73]$$

وذلك لأن:

$$\mathbf{E} X = \sum_{i=1}^n x_i \cdot P(X = x_i) = \sum_{i=1}^n x_i \cdot \mathbf{E}(I_{A_i}) = \sum_{i=1}^n x_i \cdot P(A_i)$$

والآن لو أخذنا $\mathcal{Z} = \{Z_j \subseteq \Omega : j \in \mathbb{N}_k\}$ تجزئة لـ Ω ، فإنه يمكننا باستخدام الاحتمالات الشرطية $P(A_i | \mathcal{Z})$ لكل $i \in \mathbb{N}_n$ أنَّ نعرف التوقع الشرطي للمتغير العشوائي X بالنسبة إلى التجزئة \mathcal{Z} ، حيث يرمز له بـ $\mathbf{E}(X | \mathcal{Z})(\omega)$ لتبيان أنَّ هذا التوقع الشرطي هو متغير عشوائي، حيث يوضع:

$$\mathbf{E}(X | \mathcal{Z})(\omega) = \mathbf{E} \sum_{i=1}^n x_i \cdot P(A_i | \mathcal{Z})(\omega) \quad [7,74]$$

(٢, ٥, ٧) ملاحظات

١- وفقاً لهذا التعريف يكون التوقع الشرطي للمتغير العشوائي X بالنسبة إلى تجزئة \mathcal{Z} هو متغير عشوائي فوق $[\Omega, \mathcal{A}, P]$ ، وقيمه من أجل أي حدث ابتدائي $\omega \in Z_j$ يساوي $\sum_{i=1}^n x_i P(A_i | Z_j)$. إنَّ هذه الملاحظة توضح لنا أنه كان بالإمكان التوصل إلى تعريف التوقع الشرطي لمتغير عشوائي X بالنسبة إلى تجزئة \mathcal{Z} من خلال تعريف التوقع الشرطي $\mathbf{E}(X | Z_j)$ وذلك باستخدام العلاقة الآتية:

$$\mathbf{E}(X \cdot I_{Z_j}) = \sum_{i=1}^n x_i P(A_i | Z_j)$$

والتي تعطينا العلاقة الآتية:

$$\mathbf{E}(X | Z_j) = \sum_{i=1}^n x_i P(A_i | Z_j) \quad [7,75]$$

وبعد ذلك لو وضعنا بالتعريف ما يلي:

$$\mathbf{E}(X | \mathcal{Z}) := \sum_{j=1}^k \mathbf{E}(X | Z_j) \cdot I_{Z_j} \quad [7,76]$$

سيصبح لدينا ما يلي مُحَقَّقاً:

$$\mathbf{E}(X | \mathcal{Z})(\omega) = \sum_{j=1}^k \mathbf{E}(X | Z_j) \cdot I_{Z_j}(\omega) \quad ; \forall \omega \in \Omega \quad [7,77]$$

٢- يتبين لنا من العروض السابقة أنَّ $\mathbf{E}(X | \mathcal{Z})$ و $\mathbf{E}(X | Z_j)$ غير متعلِّقة بنوعية العرض للمتغير العشوائي X .

٣- يمكننا كتابة $\mathbf{E}(X | Z_j)$ على النحو الآتي أيضاً:

$$\mathbf{E}(X | Z_j) = \frac{\mathbf{E}(X \cdot I_{Z_j})}{P(Z_j)} \quad ; \forall j \in \mathbb{N}_k$$

(٧, ٥, ٢, ٣) تعريف (التجزئة التي أنعم من تجزئة أخرى Partition Smoother Than Another Partition)

لتكن \mathcal{Z}_1 و \mathcal{Z}_2 تجزئتين مختلفتين لـ Ω ، فعندئذ يُقال إنَّ التجزئة \mathcal{Z}_1 أنعم من التجزئة \mathcal{Z}_2 إذا كان من أجل كل ذرة $A \ni \mathcal{Z}_1$ توجد ذرة $B \ni \mathcal{Z}_2$ بحيث تكون $B \supseteq A$ ، وسنرمز لذلك بـ $\mathcal{Z}_1 \gg \mathcal{Z}_2$.

(٧, ٥, ٢, ٤) تعريف (المتغير العشوائي القيوس بالنسبة إلى تجزئة)

Random Variable, that is measurable with respect to a Partition

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، و \mathcal{Z}_X تجزئة مولدة من X ، وبفرض أن \mathcal{Z} تجزئة ما لـ Ω . عندئذ يُقال إنَّ المتغير العشوائي X قيوس بالنسبة إلى التجزئة \mathcal{Z} (أو يُقال X هو \mathcal{Z} -قيوس (X is \mathcal{Z} -measurable)) إذا كانت $\mathcal{Z}_X \gg \mathcal{Z}$. لاحظ هنا أنه إذا كان X قيوساً بالنسبة إلى التجزئة $\mathcal{Z} = \{Z_j \subseteq \Omega : j \in \mathbb{N}_k\}$ فإنَّ المتغير العشوائي X سيكون قابلاً للعرض من خلال العلاقة الآتية:

$$X(\omega) = \sum_{i=1}^k x_i \cdot \mathbf{I}_{Z_i}(\omega) \quad [7,78]$$

ومن هذا يتضح لنا أنَّ المتغير العشوائي X سيكون قيوساً بالنسبة إلى التجزئة \mathcal{Z} إذا كان X يأخذ قيماً ثابتة على ذرات التجزئة \mathcal{Z} (أي إنَّ X شكل دالة درجية على ذرات التجزئة \mathcal{Z})، وكمثال على ذلك لو أخذنا $\mathcal{Z} = \{\Omega\}$ هي التجزئة المبتدلة، فعندئذ سيكون X قيوساً بالنسبة إلى التجزئة \mathcal{Z} إذا وفقط إذا كان X ثابتاً على Ω باحتمال يساوي الواحد، أي إنَّ X خاضع للتوزيع الوحيد النقطة.

(٧, ٥, ٢, ٥) نتيجة

إنَّ أي متغير عشوائي X فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ سيكون قيوساً بالنسبة إلى التجزئة المولدة منه \mathcal{Z}_X وذلك لأنه يأخذ قيماً ثابتة على ذراتها.

(٧, ٥, ٢, ٦) ملاحظات

١- عندما تكون التجزئة \mathcal{Z} مولدة من متغيرات عشوائية Y_1, Y_2, \dots, Y_m ، أي إنَّ $\mathcal{Z} = \mathcal{Z}_{Y_1, Y_2, \dots, Y_m}$ ، فعندئذ يرمز للتوقع الشرطي لـ X بالنسبة إلى التجزئة $\mathcal{Z}_{Y_1, Y_2, \dots, Y_m}$ بالرمز $E(X | Y_1, Y_2, \dots, Y_m)(\omega)$ ويطلق عليه اسم التوقع الشرطي لـ X بالنسبة إلى المتغيرات العشوائية Y_1, Y_2, \dots, Y_m .

٢- من تعريف $E(X | Y)$ ينتج لدينا أنه إذا كان X و Y مستقلان بعضهما عن بعض فإنَّ العلاقة الآتية ستكون محققة:

$$E(X | Y) = EX \quad [7,79]$$

وذلك لأنه لدينا:

$$E(X | Y) = E(X | \mathcal{Z}_Y)(\omega) = \sum_k E(X | Z_k) \cdot \mathbf{I}_{Z_k}(\omega)$$

وبما أن $\sum_{k=1}^m \mathbf{I}_{Z_k}(\omega) = 1$ وكذلك لدينا:

$$E(X | Z_k) = \sum_i x_i \cdot P(A_i | Z_k) = EX$$

وبهذا تنتج لدينا صحة العلاقة [7,79].

٣- لدينا $E(X | X) = X$ ، وذلك لأنَّ:

$$E(X | X) = E(X | \mathcal{Z}_X)(\omega) = \sum_k E(X | Z_k) \cdot \mathbf{I}_{Z_k}(\omega) = \sum_k \sum_{\ell} x_{\ell} P(Z_{\ell} | Z_k) \mathbf{I}_{Z_k}(\omega)$$

ولكن لدينا:

$$P(A_\ell | A_k) = \begin{cases} 1 & \text{for } \ell = k \\ 0 & \text{for } \ell \neq k \end{cases}$$

ومنه ينتج لدينا:

$$\sum_k \sum_\ell x_\ell P(Z_\ell | Z_k) \mathbf{I}_{Z_k}(\omega) = \sum_k x_k \cdot \mathbf{I}_{Z_k}(\omega) = X(\omega)$$

وبهذا يتم الإثبات.

سنقدم فيما يلي بعض خصائص التوقع الشرطي وفقاً للطرح المقدم سابقاً، وهذه الخصائص سنراها ذاتها لدى تقديم العرض المعمم للتوقع الشرطي، وأما الإثباتات لهذه الخصائص فسوف تترك كتمارين للقارئ.

(٧, ٥, ٢, ٧) مبرهنة (خصائص التوقع الشرطي بالنسبة إلى تجزئة)

ليكن X و Y متغيرين عشوائيين فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، ولناخذ $\mathcal{Z} = \{Z_i \subseteq \Omega : i \in \mathbb{N}_k\}$ تجزئة لـ Ω ، فعندئذ:

١- بفرض أن a و b أعداد حقيقية مع $a \neq 0$ ، فإنه سيكون لدينا:

$$\mathbf{E}(aX + bY | \mathcal{Z}) = a \cdot \mathbf{E}(X | \mathcal{Z}) + b \cdot \mathbf{E}(Y | \mathcal{Z})$$

٢- من أجل التجزئة المبتذلة $\mathcal{Z} = \{\Omega\}$ لدينا:

$$\mathbf{E}(X | \{\Omega\}) = \mathbf{E}X$$

٣- إذا كان $X = c$ على Ω باحتمال يساوي الواحد، فإنه سيكون لدينا:

$$\mathbf{E}(X | \mathcal{Z}) = c$$

٤- من أجل أي حدث $A \in \mathcal{A}$ يكون لدينا:

$$\mathbf{E}(\mathbf{I}_A | \mathcal{Z})(\omega) = P(A | \mathcal{Z})(\omega) \quad [7,80]$$

ومن هذه العلاقة يتبين لنا أن خصائص الاحتمال الشرطي يمكن الحصول عليها مباشرة من خصائص التوقع الشرطي.

٥- لدينا العلاقة الآتية محققة دوماً:

$$\mathbf{E}[\mathbf{E}(X | \mathcal{Z})] = \mathbf{E}X \quad [7,81]$$

إن هذه الخاصية تعمم لنا صيغة الاحتمال التام المعطى من خلال العلاقة [7,67]، وذلك لأنه إذا أخذنا الحالة الخاصة $X = \mathbf{I}_A$ فإن [7,67] ستنتج من العلاقة السابقة [7,81].

٦- يكون X قيوساً بالنسبة إلى التجزئة \mathcal{Z} إذا كان X يأخذ قيماً ثابتة على ذرات هذه التجزئة، وهذه الحقيقة تنتج مباشرة من العلاقة [7,78].

٧- إذا كان X قيوساً بالنسبة إلى التجزئة \mathcal{Z} ، فعندئذ ستكون العلاقة الآتية محققة:

$$\mathbf{E}(X \cdot Y | \mathcal{Z}) = X \cdot \mathbf{E}(Y | \mathcal{Z}) \quad [7,82]$$

وبشكل خاص عندما $Y = 1$ باحتمال يساوي الواحد، فإنه سينتج لدينا:

$$E(X | Z) = X \quad \& \quad E(X | Z_X) = X$$

٨- لتكن Z_1 و Z_2 تجزئتين لـ Ω بحيث إن $Z_1 \cap Z_2 = \emptyset$ ، فعندئذ يكون لدينا:

$$E[E(X | Z_2) | Z_1] = E(X | Z_1) \quad [7,83]$$

(٧, ٥, ٢, ٨) نتائج:

١- من تعريف $E(X | Y)$ ينتج أنه إذا كان X و Y مستقلين فإن العلاقتين الآتيتين ستكونان محققتين:

$$a) E(X | Y) = X \quad \& \quad b) E(Y | X) = Y \quad [7,84]$$

٢- إن الخاصية (a) من [7,84] تسمح لنا بالتعميم الآتي:

إذا كان X مستقلاً عن التجزئة Z ، أي إنه من أجل كل $Z_j \in Z$ يكون X و I_{Z_j} مستقلين بعضهما عن بعض، فعندئذ سيكون لدينا:

$$E(X | Z) = EX \quad [7,85]$$

٣- من العلاقة السابقة [7,85] نحصل بشكل خاص على العلاقة الآتية:

$$E[E(X | Y_1, Y_2) | Y_1] = E(X | Y_1) \quad [7,86]$$

(٧, ٥, ٢, ٩) ملاحظات

١- نعلم أنه في حال أن Ω منتهية فإن مفهوم الجبر وال σ -جبر فوق Ω سيكونان متطابقان، ولهذا فإن التوقع الشرطي لمتغير عشوائي X بالنسبة إلى جبر ما \mathcal{B} فوق Ω سيتطابق مع مفهوم التوقع الشرطي لمتغير عشوائي X بالنسبة إلى تجزئة مولدة للجبر \mathcal{B} ، فلو كان $\mathcal{B} = \alpha(Z)$ هو الجبر المولد من التجزئة Z فإنه يفهم من $E(X | \mathcal{B})$ على أنه بالتعريف هو $E(X | Z)$.

٢- في مجال الإحصاء الرياضي تُعرف الدالة:

$$R(y_j) = E(X | Y = y_j) \quad [7,87]$$


باسم معادلة انحدار Regression Equation المتغير X على Y ، وأما المنحنى الناتج عن المجموعة $\{R(y_j); j \in J\}$ فإنه يُعرف باسم خط انحدار Regression Line المتغير X على Y ، وبالمثل يُطلق على الدالة:

$$R(x_i) = E(Y | X = x_i) \quad [7,88]$$


اسم معادلة انحدار المتغير Y على X ، وأما المنحنى الناتج عن المجموعة $\{R(x_i); i \in I\}$ فإنه يُدعى خط انحدار Y على X .

أخيراً نشير هنا إلى أن المعادلتين [7,87] و [7,88] تُدعيان معادلتَي الانحدار للمسألة الإحصائية التي قيد الدراسة.

في الواقع يُنظر إلى كل من المتغيرين العشوائيين X و Y على أنها مركبات متجهة عشوائي $X_2 = (X, Y)$ راصد للملاحظة خاصة بالتجربة التي قيد الدراسة، فعلى سبيل المثال لو كان للمتجه العشوائي $X_2 = (X, Y)$ توزيع طبيعي (ثنائي البعد) حيث يبرهن على أن التوزيعين الهامشيين لكل من X و Y سيكون لهما توزيع طبيعي أيضاً، فعندئذ سيكون لبيان الدالتين الممثلتين لمعادلتَي الانحدار خطان واقعان في المستوى XOY والمشار إليهما في الشكلين الآتين (١، ٧. أ) و (١، ٧. ب).



الشكل (١، ٧، أ)



الشكل (١، ٧، ب)

مثال (١٠، ٢، ٥، ٧):

ليكن X و Y متغيرين عشوائيين مستقلين متطابقين التوزيع وأخذان القيمتين 1 و 0 باحتمال $0 < p < 1$ و $q = 1 - p$ على الترتيب، ولنقم بما يلي:

أ- حساب الاحتمال الشرطي $P(X + Y = k | Y)$ وذلك من أجل أي $k \in \{0, 1, 2\}$.

ب- حساب التوقع الشرطي $E(X + Y | Y)$.

الحل: من أجل ذلك نعلم أنه إذا كان X و Y متغيرين عشوائيين مستقلين وأخذان القيمتين x و y على الترتيب، فإنه سيكون لدينا ما يلي مُحَقَّقًا:

$$P(X + Y = z | Y = y) = P(X + y = z)$$

وذلك لأنه باستخدام تعريف الاحتمال الشرطي ومفهوم الاستقلال نجد الآتي:

$$\begin{aligned} P(X + Y = z | Y = y) &= \frac{P(X + Y = z, Y = y)}{P(Y = y)} = \frac{P(X + y = z, Y = y)}{P(Y = y)} \\ &= \frac{P(X + y = z) \cdot P(Y = y)}{P(Y = y)} = P(X + y = z) \end{aligned}$$

ومن ثمَّ باستخدام هذه العلاقة الأخيرة نجد أنَّ:

$$P(X + Y = k | Y) = P(X + Y = k | Y = 0) \cdot \mathbf{I}_{\{Y=0\}}(\omega) + P(X + Y = k | Y = 1) \cdot \mathbf{I}_{\{Y=1\}}(\omega)$$

وهذه العلاقة الأخير يمكننا كتابتها بالشكل الآتي:

$$P(X + Y = k | Y) = P(X = k) \cdot \mathbf{I}_{\{Y=0\}}(\omega) + P(X = k - 1) \cdot \mathbf{I}_{\{Y=1\}}(\omega)$$

والتي نجد منها:

$$P(X + Y = k | Y) = \begin{cases} q \cdot \mathbf{I}_{\{Y=0\}}(\omega) & \text{for } k = 0 \\ p \cdot \mathbf{I}_{\{Y=0\}}(\omega) + q \cdot \mathbf{I}_{\{Y=1\}}(\omega) & \text{for } k = 1 \\ p \cdot \mathbf{I}_{\{Y=1\}}(\omega) & \text{for } k = 2 \end{cases}$$

وهكذا ينتج لدينا الآتي:

$$P(X + Y = k | Y) = \begin{cases} q \cdot (1 - Y) & \text{for } k = 0 \\ p \cdot (1 - Y) + q \cdot Y & \text{for } k = 1 \\ p \cdot Y & \text{for } k = 2 \end{cases}$$

ب- من العلاقتين (a) و (b) من [7,84]، وبسبب استقلال X عن Y ينتج لدينا:

$$\mathbf{E}(X + Y | Y) = \mathbf{E}(X | Y) + \mathbf{E}(Y | Y) = \mathbf{E}X + Y = p + Y$$

وكان من الممكن الحصول على هذه النتيجة اعتماداً على تعريف التوقع الشرطي لمتغير عشوائي أيضاً، وبهذا يتم الحل.

هذا ما تيسر تقديمه من أجل الجزء النظري والتطبيقي لهذا الفصل

تمارين الفصل السابع

١- لنأخذ تجربة قذف قطعة نقود متوازنة لثلاث مرات متتالية، وليكن X, Y, Z ثلاثة متغيرات عشوائية فوق الفضاء الاحتمالي لهذه التجربة العشوائية، ومعرفة كما يلي:

$$X(\omega) := \begin{cases} -1 & \text{for } \omega = \{HHH\} \\ 1 & \text{for } \omega = \{TTT\} \\ 0 & \text{otherwise} \end{cases}$$

$$Y(\omega) := \begin{cases} 1 & \text{for } \omega = \{TTT, HHH\} \\ -1 & \text{for } \omega = \{THH, HTH, HHT\} \\ 0 & \text{for } \omega = \{THT, TTH, HTT\} \end{cases}$$

$$Z(\omega) := \begin{cases} -1 & \text{for } \omega = \{HHH, HHT, HTH, THH\} \\ 1 & \text{for } \omega = \{TTT, TTH, THT, HTT\} \end{cases}$$

والمطلوب ما يلي:

- أ- بين إن كانت هذه المتغيرات العشوائية مستقلة أم لا؟
 - ب- احسب التباين للمتغير العشوائي X وفقاً لتعريف التباين.
 - ج- عين الدالة المولدة لعزوم المتغير العشوائي Y ، ومن ثم استخدمها من أجل حساب التباين لهذا المتغير العشوائي.
 - د- عين الدالة المميزة للمتغير العشوائي Z ، ومن ثم استخدمها من أجل حساب التباين لهذا المتغير العشوائي.
 - هـ- احسب قيمة معامل الارتباط الخطي بين X و Z ، ومن ثم ناقش قيمته.
- ٢- لنأخذ تجربة إلقاء حجر نرد متمايزين ومتوازنين لمرة واحدة فقط، وليكن X و Y متغيرين عشوائيين فوق الفضاء الاحتمالي لهذه التجربة معرفين من خلال العلاقتين الآتيتين:

$$X((i, j)) := \begin{cases} -2 & \text{for } i + j \leq 4 \\ 0 & \text{for } 4 < i + j \leq 8 \\ 6 & \text{for } i + j > 8 \end{cases}$$

$$Y((i, j)) := \begin{cases} 0 & \text{for } i + j \leq 7 \\ 1 & \text{for } i + j > 7 \end{cases}$$

والمطلوب ما يلي:

- أ- بين إن كان X مستقل عن Y أم لا؟
- ب- احسب التباين لكل من المتغيرين العشوائيين X و Y وفقاً لتعريف التباين.
- ج- عين الدالة المولدة لعزوم المتغير العشوائي Y ، ومن ثم استخدمها من أجل حساب التباين لهذا المتغير العشوائي.
- د- عين الدالة المميزة للمتغير العشوائي X ، ومن ثم استخدمها من أجل حساب التباين لهذا المتغير العشوائي.

- هـ- احسب قيمة معامل الارتباط الخطي بينهما وناقش قيمته.
- و- إذا كانت g دالة حقيقية معرفة على \mathbb{R} من خلال العلاقة $g(x) = (x-1)^2$ ، فعندئذ عين الدالة المولدة لعزوم المتغير العشوائي Z المعطى بالعلاقة $Z = g(X) = (X-1)^2$ ، ومن ثم استخدم هذه الدالة في حساب $E Z$ و $\text{var } Z$.
- ٣- أثبت أن كل متغير عشوائي تباينه معدوم سيكون خاضعاً للتوزيع الوحيد النقطة.
- ٤- ليكن X متغيراً عشوائياً خاضعاً للتوزيع الطبيعي $N(\mu, \sigma)$ والمطلوب ما يلي:
- أ- حساب التباين لهذا المتغير العشوائي.
- ب- تعيين الدالة المولدة لعزومه.
- ٥- عين العزوم الابتدائية حتى المرتبة الرابعة للمتغيرات العشوائية الآتية مستخدماً دوالها المميزة:
- أ- متغير عشوائي خاضع للتوزيع الوحيد النقطة عند القيمة $c = 0$.
- ب- متغير عشوائي خاضع للتوزيع الحداني بمعلمتين $n = 50$ و $p = 0.25$.
- ج- متغير عشوائي خاضع للتوزيع الأسّي بمعلمة $\lambda = 0.5$.
- ٦- ليكن X متغيراً عشوائياً خاضعاً للتوزيع المنتظم المتقطع بمعلمة $N \ni n$ ، والمطلوب تعيين الدالة المولدة لعزومه وكذلك الدالة المميزة له، ومن ثم استخدمهما في حساب التوقع الرياضي والتباين لهذا المتغير العشوائي.
- ٧- ليكن $X \sim G(p)$ متغيراً عشوائياً، فعندئذ عين الدالة المولدة لعزومه، ومن ثم استخدمهما في حساب التوقع الرياضي والتباين لهذا المتغير العشوائي.
- ٨- لنأخذ $X \sim EX(\lambda)$ متغيراً عشوائياً، فعندئذ عين دالته المولدة الاحتمالية.
- ٩- استخدم خصائص الدالة المولدة الاحتمالية لتوليد العزوم الابتدائية من المرتبة الأولى والثانية للمتغيرات العشوائية الآتية:
- أ- المتغير العشوائي $X \sim P(\lambda)$.
- ب- المتغير العشوائي $X \sim U([a, b])$.
- ج- المتغير العشوائي $X \sim EX(\lambda)$.
- ١٠- بفرض أن X و Y متغيران عشوائيان يملكان توقعاً رياضياتياً مع $P(Y \neq 0) = 1$ و $EY \neq 0$ ، فعندئذ بين من خلال مثال مناسب (غير الذي قدم في هذا الفصل) أن $E \frac{X}{Y} \neq \frac{EX}{EY}$.
- ١١- ليكن X متغيراً عشوائياً مستمراً بدالة كثافة احتمالية:
- $$f_X(x) = \frac{1}{2} e^{-|x|} \quad ; \forall x \in \mathbb{R}$$
- والمطلوب تعيين الدالة المميزة $\varphi_X(t)$ لهذا المتغير العشوائي.

١٢- ليكن X متغيراً عشوائياً بدالة مميزة $\varphi_X(t) = \frac{1}{1+t^2}$ ، والمطلوب تعيين العزوم حتى المرتبة الثالثة لهذا المتغير العشوائي.

١٣- بفرض أن X_1, X_2, \dots, X_n متغيرات عشوائية مستقلة فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فعندئذ أثبت صحة العلاقة الآتية:

$$\varphi_{X_1+X_2+\dots+X_n}(t) = \prod_{k=1}^n \varphi_{X_k}(t) \quad ; \forall t \in \mathbb{R}$$

١٤- تحت الفرضيات المقدمة في المبرهنة (٥، ٢، ٣، ٧) اثبت صحة العلاقة الآتية:

$$G_Y(s) = G_\zeta(G_X(s)) \quad ; \forall s \in \mathbb{R}$$

١٥- ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ بدالة مولدة احتمالية G_X ، فعندئذ أثبت صحة العلاقة الآتية:

$$E[X \cdot (X-1) \cdot \dots \cdot (X-k+1)] = G_X^{(k)}(1)$$

علماً أن $G_X^{(k)}(1)$ هي كتابة مختصرة للصيغة $\lim_{s \uparrow 1} G_X^{(k)}(s)$.

١٦- ليكن $X \sim \text{CO}(\mu, \lambda)$ متغيراً عشوائياً، والمطلوب تعيين دالته المميزة φ_X .

١٧- بالعودة إلى المثال / ١ / من (٤، ٢، ٥، ٥) حيث لدينا $X_2 = (X, Y)$ متجهاً عشوائياً متقطعاً بدالة احتمالية كتلية مُعطاة بالعلاقة الآتية:

$$p_{ij} = \begin{cases} \frac{7}{21} & \text{for } i=1, 2 \text{ \& } j=1 \\ \frac{4}{21} & \text{for } i=1 \text{ \& } j=2 \\ \frac{3}{21} & \text{for } i=2 \text{ \& } j=2 \end{cases}$$

فهل المتغير العشوائي X مستقل عن Y ؟

١٨- بالعودة إلى المثال / ٢ / من (٤، ٢، ٥، ٥) حيث لدينا $X_2 = (X, Y)$ متجهاً عشوائياً مستمراً بدالة كثافة احتمالية مُعطاة على النحو الآتي:

$$f_{X_2}(x, y) = \begin{cases} 4xy & \text{for } (x, y) \in [0, 1] \times [0, 1] \\ 0 & \text{otherwise} \end{cases}$$

فهل المتغيران العشوائيان X و Y مستقلان عن بعضهما؟

١٩- بالعودة إلى التمرين / ١٤ / من تمارين الفصل الخامس حيث لدينا $X_2 = (X, Y)$ متجهاً عشوائياً مستمراً بدالة كثافة احتمالية مُعطاة بالعلاقة الآتية:

$$f_{X_2}(x, y) = \begin{cases} \alpha(x+y) & \text{for } (x, y) \in A \\ 0 & \text{OW.} \end{cases}$$

فهل المتغيران العشوائيان X و Y مستقلان عن بعضهما؟

٢٠- بالعودة إلى التمرين / ١٥ / من تمارين الفصل الخامس حيث لدينا $X_2 = (X, Y)$ متجهاً عشوائياً مستمراً بدالة كثافة احتمالية مُعطاة بالعلاقة الآتية:

$$f_{X_2}(x, y) = \begin{cases} e^{\alpha(x+y)} & \text{for } (x, y) \in A \\ 0 & \text{otherwise} \end{cases}$$

فهل المتغيران العشوائيان X و Y مستقلان عن بعضهما؟

٢١- ليكن X و Y متغيرين عشوائيين بمجموعتي قيم $\mathbf{X} = \{x_i; i \in \mathbb{N}_k\}$ و $\mathbf{Y} = \{y_j; j \in \mathbb{N}_\ell\}$ على الترتيب، علماً أن $\mathbb{N} \ni \ell, k$ عدنان محدودان ومُثبتان. فإذا كان X و Y مستقلين ومتطابقين التوزيع، فعندئذ أثبت صحة العلاقة الآتية:

$$\mathbf{E}(X | X + Y) = \mathbf{E}(Y | X + Y) = \frac{X + Y}{2}$$

علماً أن $P(X = x_i, Y = y_j) > 0$ من أجل كل $i \in \mathbb{N}_k$ وأي $j \in \mathbb{N}_\ell$.

الفصل الثامن

بعض نظريات النهاية المركزية

SOME CENTRAL LIMIT THEOREMS

تمهيد

لقد كانت دراساتنا في الفصول الأخيرة مركزة على عددمنته من المتغيرات العشوائية، ولكن الكثير من الدراسات النظرية التي تسعى إلى تعميم نموذج ما من التجارب العشوائية من خلال أخذ القياسات، أو الملاحظات التي تتمخض عنها تكرارات كثيرة جداً لدراسة تجربة عشوائية، أو ظاهرة عشوائية ما، كأن نفترض إمكانية إلقاء قطعة نقود معدنية لعدد غير منته من المرات، أو تكرار تجربة كيميائية لعدد غير منته من المرات، أو.... هنا نلاحظ أن كل تكرار لتجربة يمثل متغير عشوائي، فعلى سبيل المثال كل تكرار لتجربة إلقاء قطعة نقود معدنية يمثلها متغير عشوائي برنولي بتوزيع معلوم معلّمته $0 < p < 1$ تحدّد قيمته بحسب معلوماتنا عن المادة المصنّعة منها القطعة المعدنية، فإن كانت المادة التي صنّعت منها هذه القطعة المعدنية متجانسة، وعملية سبك النقد تتم بحيث يكون مركز ثقل القطعة المعدنية في مركزها تماماً، فعندئذ نفترض أنها متوازنة، ويكون لدينا في هذه الحالة $p = \frac{1}{2}$.

في الحقيقة إن الدوافع وراء هذه الدراسات النظرية عديدة منها على سبيل المثال لا الحصر إيجاد حلول تقريبية لبعض مسائل الاحتمالات ذات الطابع التطبيقي، وذلك باستخدام توزيعات شهيرة معلومة التوزيع، وسهلة الحساب، وعلى أي حال، فهذه الدراسات الناتجة عن هذه التكرارات غير المنتهية (افترضنا) تجل لنا متتاليات لمتغيرات عشوائية بخصائص مميزة (كالاستقلال مثلاً)، وقد تكون معلومة التوزيع في بعض الحالات عندها ينصب الاهتمام على معرفة التوزيع الذي تؤول إليه هذه المتتالية. بمعنى أنه إذا كانت متتالية متغيرات عشوائية (تلك التي ذكرنا آنفاً) متقاربة فما هو توزيع المتغير العشوائي الذي يمثل النهاية لهذه المتتالية؟

الآن، وبما أن كل متغير عشوائي هو تطبيق بقيم عشوائية، فإن دراسة توزيع المتغير العشوائي الذي يمثل النهاية لمتتالية متغيرات عشوائية معطاة يتطلب تقديم مفاهيم محدّدة لتقارب متتاليات المتغيرات العشوائية أسوة بمفاهيم التقارب لمتتاليات الدوال. لذلك سنقوم فيما يلي بتقديم مبسط وموجز لبعض مفاهيم تقارب متتاليات المتغيرات العشوائية، وبعد ذلك الانتقال إلى البحث في سلوك المتغير العشوائي الذي يمثل النهاية لمتتالية متغيرات عشوائية، وفي هذا الخصوص سنورد بعض المصطلحات ونذكر بالعديد من الحقائق المهمة لتبسيط الدراسة (التي من المفترض أن يكون القارئ على اطلاع بمعظمها)، وكذلك سنقوم بتقديم بعض البراهين، ونتجاوز عن تلك البراهين الطويلة والمعقّدة حيث يمكن لمن يود الاطلاع على تفاصيل هذه البراهين، أو يرغب في معرفة المزيد من المعلومات حول هذه المواضيع، الرجوع إلى المراجع ذات الصلة ومنها [10] و [14] و [24] و [28] و [39] و [46] و [53] في فهرس المراجع لهذا الكتاب.

سنبدأ دراستنا للموضوع المذكور أعلاه بتقديم بعض المفاهيم التي تتعلّق بتقارب متتاليات المتغيرات العشوائية.

(٨, ١) تقارب متتاليات المتغيرات العشوائية

Convergence of Sequences of Random Variables

في الواقع إن دراسة التقارب لمتتاليات المتغيرات العشوائية تحتاج إلى تأسيس جيد في نظرية القياس (للمساعدة يمكن الاطلاع على الملحق B)، ولكن في دراستنا هذه سنوجز بعض الأفكار الضرورية لمسار دراستنا فقط.

(٨, ١, ١) أشهر أنواع التقارب لمتتاليات المتغيرات العشوائية

نقدم فيما يلي بعضاً من أنواع التقارب لمتتاليات المتغيرات العشوائية ونبدأها بالتعريف الآتي.

(٨, ١, ١, ١) تعريف (التقارب بالتوزيع Converges in Distribution)

لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$. عندئذ يُقال عن المتتالية $(X_n)_{n \in \mathbb{N}}$ إنها **تقارب بالتوزيع** من متغير عشوائي X فوق $[\Omega, \mathcal{A}, P]$ (ويرمز لذلك بـ $X_n \xrightarrow{d} X$) إذا كان من أجل أية دالة حقيقية f مستمرة ومحدودة على \mathbb{R} لدينا العلاقة الآتية مُحَقَّقة:

$$\lim_{n \rightarrow \infty} E[f(X_n)] = E[f(X)] \quad [8,1]$$

(٨, ١, ١, ٢) تعريف (التقارب بالاحتمال Converges in probability)

لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$. عندئذ يُقال إن المتتالية $(X_n)_{n \in \mathbb{N}}$ **تقارب بالاحتمال** من متغير عشوائي X فوق $[\Omega, \mathcal{A}, P]$ (ويرمز لذلك بـ $X_n \xrightarrow{P} X$) إذا كان من أجل كل $0 < \varepsilon$ العلاقة الآتية مُحَقَّقة:

$$\lim_{n \rightarrow \infty} P(|X_n - X| > \varepsilon) = 0 \quad [8,2]$$

(٨, ١, ١, ٣) تعريف (التقارب باحتمال يساوي الواحد Converges with probability equal to one)

لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$. عندئذ يُقال إن المتتالية $(X_n)_{n \in \mathbb{N}}$ **تقارب من متغير عشوائي X فوق $[\Omega, \mathcal{A}, P]$ باحتمال يساوي الواحد** (ويرمز لذلك بـ $X_n \xrightarrow{a.s.} X$) إذا تحققت العلاقة الآتية:

$$P\left(\lim_{n \rightarrow \infty} X_n = X\right) = 1 \quad [8,3]$$

وتجدر الإشارة هنا إلى أن متتالية المتغيرات العشوائية المتقاربة باحتمال يساوي الواحد يقال عنها إنها **تقارب تقريباً أكيداً** (أو شبه أكيد) Converges Almost Sure أيضاً.

(٨, ١, ١, ٤) تعريف (التقارب بالمتوسط p - mean Converges in p -mean)

لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$. عندئذ يُقال إن المتتالية $(X_n)_{n \in \mathbb{N}}$ **تقارب بالمتوسط p** من متغير عشوائي X فوق $[\Omega, \mathcal{A}, P]$ إذا تحققت العلاقة الآتية:

$$\lim_{n \rightarrow \infty} E|X_n - X|^p = 0 \quad [8,4-a]$$

علماً أن $0 < p < \infty$ ، ويرمز لهذا التقارب بالشكل $X_n \xrightarrow{i.p.m.} X$ ، وفي الحالة الخاصة عندما يكون لدينا $p = 2$ فإن هذا النوع من التقارب يُدعى **التقارب بالمتوسط التربيعي** Convergence in Square Mean، وحينئذ يرمز له بـ $X_n \xrightarrow{i.s.m.} X$ ، أو يكتب على النحو الآتي:

$$X = l.i.m. X_n \quad [8,4-b]$$

(٨, ١, ٢) تقارب متتاليات المتغيرات العشوائية

نقدم فيما يلي بعض المبرهنات المهمة (سنقبلها جميعاً دون برهان) التي توضح لنا حقائق عديدة تتعلق بهذه الأنواع من التقاربات بالإضافة إلى إظهار بعض الاقتضاءات الممكنة بين هذه الأنواع من التقاربات لمتتاليات المتغيرات العشوائية.

(٨, ١, ٢, ١) مبرهنة

لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$. عندئذ:

١- تكون هذه المتتالية متقاربة من متغير عشوائي X فوق $[\Omega, \mathcal{A}, P]$ باحتمال يساوي الواحد إذا وفقط إذا كان من أجل كل $0 < \varepsilon$ لدينا ما يلي محققاً:

$$\lim_{n \rightarrow \infty} P \left(\sup_{k \geq n} |X_k - X| \geq \varepsilon \right) = 0 \quad [8,5]$$

٢- تكون هذه المتتالية أساسية Essentially Sequence (أو متتالية كوشي Cauchy Sequence) باحتمال يساوي الواحد إذا كان من أجل كل $0 < \varepsilon$ لدينا ما يلي محققاً:

$$\lim_{n \rightarrow \infty} P \left(\sup_{k \geq n, \ell \geq n} |X_k - X_\ell| \geq \varepsilon \right) = 0 \quad [8,6-a]$$

وهي تكافئ العلاقة الآتية أيضاً:

$$\lim_{n \rightarrow \infty} P \left(\sup_{k \geq 1} |X_{n+k} - X_n| \geq \varepsilon \right) = 0 \quad [8,6-b]$$

(٨, ١, ٢, ٢) نتيجة

بما أن:

$$\left\{ \omega \in \Omega ; \sup_{k \geq n} |X_k(\omega) - X(\omega)| \geq \varepsilon \right\} = \left\{ \omega \in \Omega ; \bigcup_{k \geq n} |X_k(\omega) - X(\omega)| \geq \varepsilon \right\}$$

فإنه سيكون لدينا:

$$P \left(\sup_{k \geq n} |X_k - X| \geq \varepsilon \right) = P \left(\bigcup_{k \geq n} |X_k - X| \geq \varepsilon \right) \leq \sum_{k \geq n} P(|X_k - X| \geq \varepsilon)$$

ومن ثم إذا كانت متتالية المتغيرات العشوائية $(X_n)_{n \in \mathbb{N}}$ متقاربة من متغير عشوائي X فوق $[\Omega, \mathcal{A}, P]$ باحتمال يساوي الواحد، فعندئذ سيكون من أجل كل $0 < \varepsilon$ لدينا العلاقة الآتية محققة:

$$\sum_{n=1}^{\infty} P(|X_n - X| \geq \varepsilon) < +\infty \quad [8,7]$$

(٨, ١, ٢, ٣) مبرهنة

لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$. عندئذ:

- ١- إذا كانت هذه المتتالية متقاربة من متغير عشوائي X بالاحتمال فإنها ستكون متقاربة من X بالتوزيع أيضاً.
 - ٢- إذا كانت هذه المتتالية متقاربة من X باحتمال يساوي الواحد فإنها ستكون متقاربة من X بالاحتمال أيضاً.
 - ٣- إذا كانت هذه المتتالية متقاربة من X بالمتوسط p مع $0 < p < \infty$ فإنها ستكون متقاربة من X بالاحتمال أيضاً.
- بناءً على نتائج هذه المبرهنة يمكننا أن نعرض الاقتضاءات الآتية:

$$\begin{array}{c}
 X_n \xrightarrow{a.s.} X \Rightarrow X_n \xrightarrow{P} X \Rightarrow X_n \xrightarrow{d} X \\
 \Downarrow \quad ? \quad \Uparrow \\
 \quad \quad \quad ? \\
 X_n \xrightarrow{i.p.m} X \Rightarrow X_n \xrightarrow{P} X \Rightarrow X_n \xrightarrow{d} X
 \end{array}$$

انتبه: إنَّ عكس هذه الاقتضاءات غير صحيح في الحالة العامة.

وهكذا نجد أنه في الحالة العامة إذا كانت $X_n \xrightarrow{a.s.} X$ فإنَّ ذلك لا يقتضي أن تكون $X_n \xrightarrow{i.p.m} X$ ، وكذلك إذا كانت $X_n \xrightarrow{i.p.m} X$ فإنَّ ذلك لا يقتضي أن تكون $X_n \xrightarrow{a.s.} X$.

(٨,٢) قانون الأعداد الكبيرة

Laws of Large Numbers

من المواضيع المهمة التي تربط نظرية الاحتمالات بالإحصاء الرياضي ما يُعرف باسم **قوانين الأعداد الكبيرة** التي تقدّمها لنا التعاريف الآتية.

(٨,٢,١) تعريف قانوني الأعداد الكبيرة (الضعيف والقوي)

لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيّرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، ولنضع من أجل كل $n \in \mathbb{N}$ ما يلي:

$$S_n := X_1 + X_2 + \dots + X_n \quad [8,8]$$

فعندئذ:

١- يُقال إنَّ المتتالية $(X_n)_{n \in \mathbb{N}}$ تخضع **للقانون الضعيف للأعداد الكبيرة** Weak Law of Large Numbers إذا وجد ثابت حقيقي μ بحيث يكون:

$$\frac{S_n}{n} \xrightarrow{P} \mu \quad [8,9]$$

٢- يُقال إنَّ المتتالية $(X_n)_{n \in \mathbb{N}}$ تخضع **للقانون القوي للأعداد الكبيرة** Strong Law of Large Numbers إذا وجد ثابت حقيقي μ بحيث يكون:

$$\frac{S_n}{n} \xrightarrow{a.s.} \mu \quad [8,10]$$

(٨,٢,١,١) ملاحظات

١- من الملاحظ أنَّ قيمة $\frac{S_n}{n}$ تمثّل القيمة الوسطى (أو المتوسط) للمتغيّرات العشوائية X_1, X_2, \dots, X_n ، ولذلك يُشار عادةً إلى $\frac{S_n}{n}$ بالرمز \bar{X}_n ، أي إنّه لدينا:

$$\bar{X}_n := \frac{S_n}{n} \quad ; \forall n \in \mathbb{N} \quad [8,11-a]$$

٢- من أجل الحالة الخاصة التي يكون فيها للمتغيّرات العشوائية X_1, X_2, \dots, X_n توزيع برنولي، فإنَّ $\frac{S_n}{n}$ يمثّل التكرار النسبي لتحقّق وقوع الحادث الذي قيد الدراسة وذلك عند تكرار التجربة البرنولية تحت الشروط نفسها لـ n مرّة متتالية، ولذلك يُستخدم الرمز \bar{P}_n للدلالة على $\frac{S_n}{n}$ لتمييز معناه عن \bar{X}_n ، ولكي نتجنب الالتباس الذي يمكن أن ينشأ عن استخدام \bar{P}_n (لتشابهه مع رمز الدالة الاحتمالية P) فإنّنا سنستخدم الرمز $\bar{\pi}_n$ بدلاً عن \bar{P}_n للدلالة على $\frac{S_n}{n}$. أي إنّنا سنكتب من أجل هذه الحالة الخاصة:

$$\overline{\pi}_n := \frac{S_n}{n} \quad ; \quad \forall n \in \mathbb{N} \quad [8,11-b]$$

وإذا كانت هذه المتغيرات العشوائية البرنولية مستقلة ومتطابقة في التوزيع بمعلّمة مشترك p (يمثل احتمال النجاح في التجربة البرنولية الواحدة) فعندئذ يمثل المقدار $\frac{S_n}{n}$ عدد النجاحات خلال الـ n تكرار.

٣- بما أن التقارب باحتمال يساوي الواحد يقتضي التقارب بالاحتمال، فإنه إذا حَقَّقت متتالية متغيرات عشوائية $(X_n)_{n \in \mathbb{N}}$ قانون الأعداد الكبيرة القوي فإنها ستكون مُحَقَّقة لقانون الأعداد الكبيرة الضعيف حتماً، ولذلك يُركِّز المرء عادةً على الحالات التي تكون فيها $(X_n)_{n \in \mathbb{N}}$ مُحَقَّقة لقانون الأعداد الكبيرة القوي.

المبرهنة الآتية التي سنبرهن على إحدى نتيجتيها فقط (لمن يود الاطلاع على برهان النتيجة الأولى منها يمكنه الرجوع إلى بعض المراجع التي ذكرت في بداية هذا الفصل) تقدّم لنا ثمرة من ثمار قوانين الأعداد الكبيرة.

$$(٨, ٢, ٢) \text{ مبرهنة بخصوص تقارب المتتالية } \left(\frac{S_n}{n} \right)_{n \in \mathbb{N}}$$

لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فإذا كانت عناصر هذه المتتالية مستقلة ومتطابقة في التوزيع وتملك عزماً ابتدائياً من المرتبة الثانية، فعندئذ يكون لدينا ما يلي مُحَقَّقاً:

$$\frac{S_n}{n} \xrightarrow{a.s.} \mathbf{E}X_1 \quad [8,12-a]$$

$$\frac{S_n}{n} \xrightarrow{i.s.m.} \mathbf{E}X_1 \quad [8,12-b]$$

برهان النتيجة [8,12,b]:

بما أن عناصر المتتالية $(X_n)_{n \in \mathbb{N}}$ مستقلة، ومتطابقة التوزيع، وتملك عزماً ابتدائياً من المرتبة الثانية، فإنه يمكننا أن نكتب ما يلي:

$$\begin{aligned} \mathbf{E} \left(\frac{S_n}{n} - \mathbf{E}X_1 \right)^2 &= \mathbf{E} \left(\frac{S_n}{n} - \frac{n \mathbf{E}X_1}{n} \right)^2 = \mathbf{E} \left(\frac{S_n}{n} - \frac{1}{n} \sum_{k=1}^n \mathbf{E}X_1 \right)^2 = \mathbf{E} \left(\frac{S_n}{n} - \frac{\mathbf{E}X_1 + \mathbf{E}X_2 + \dots + \mathbf{E}X_n}{n} \right)^2 \\ &= \mathbf{E} \left(\frac{S_n}{n} - \frac{\mathbf{E}(X_1 + X_2 + \dots + X_n)}{n} \right)^2 = \mathbf{E} \left[\frac{1}{n^2} (S_n - \mathbf{E}S_n)^2 \right] = \frac{1}{n^2} \text{var } S_n \end{aligned}$$

وباستخدام خاصية الاستقلال للمتغيرات العشوائية في المتتالية $(X_n)_{n \in \mathbb{N}}$ يصبح لدينا ما يلي:

$$\mathbf{E} \left(\frac{S_n}{n} - \mathbf{E}X_1 \right)^2 = \frac{1}{n^2} \sum_{k=1}^n \text{var } X_k = \frac{1}{n} \text{var } X_1$$

ومن ثم ينتج لدينا من كون $0 < \text{var } X_1 < \infty$ ما يلي مُحَقَّقاً:

$$\lim_{n \rightarrow \infty} \mathbf{E} \left(\frac{S_n}{n} - \mathbf{E}X_1 \right)^2 = \lim_{n \rightarrow \infty} \frac{\text{var } X_1}{n} = 0$$

وهذا يعني أن $\frac{S_n}{n} \xrightarrow{i.s.m.} \mathbf{E}X_1$ ، وبذلك يتم البرهان.

(١, ٢, ٢, ٨) مثال

لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ مستقلة وبرتولية التوزيع، ولنفترض أنه من أجل كل $n \in \mathbb{N}$ لدينا $P(X_n = 1) = p_n$ و $P(X_n = 0) = 1 - p_n$ ، علماً أن $0 < p_n < 1$ ، فعندئذ بحسب الدراسة السابقة يكون لدينا $\bar{\pi}_n \xrightarrow{P} \frac{1}{n} \sum_{k=1}^n p_k$ وذلك لأنه من أجل كل $n \in \mathbb{N}$ لدينا:

$$\mathbf{E} \bar{\pi}_n = \frac{1}{n} \sum_{k=1}^n \mathbf{E} X_k = \frac{1}{n} \sum_{k=1}^n p_k$$

وكذلك:

$$\text{var } \bar{\pi}_n = \frac{1}{n^2} \text{var } S_n = \frac{1}{n^2} \sum_{k=1}^n \text{var } X_k = \frac{1}{n^2} \sum_{k=1}^n p_k (1 - p_k)$$

وباستخدام متباينة تشيبيشيف (انظر العلاقة [7,36-a] في المبرهنة (١, ٥, ٢, ٧)) يكون لدينا من أجل كل $0 < \varepsilon$ ما يلي مُحققاً:

$$P(|\bar{\pi}_n - \mathbf{E} \bar{\pi}_n| \geq \varepsilon) \leq \frac{\sqrt{\text{var } \bar{\pi}_n}}{\sqrt{\varepsilon}} \leq \frac{1}{2\sqrt{\varepsilon \cdot n}} \xrightarrow{n \rightarrow \infty} 0$$

وهذا يعني أن المتتالية $(\bar{\pi}_n)_{n \in \mathbb{N}}$ تتقارب بالاحتمال من القيمة $\mathbf{E}(\bar{\pi}_n)$.

تجدر الإشارة هنا إلى أنه إذا كانت متتالية المتغيرات العشوائية بالمواصفات الواردة في متن هذا المثال مُحقق التقارب $\frac{S_n}{n} \xrightarrow{a.s.} \mathbf{E} X_1$ ، فعندئذ يُقال إن هذه المتتالية تحقق **قانون بواسون للأعداد الكبيرة** Poisson's Law of Large Numbers، وفي الحالة الخاصة عندما يكون $p_n = p$ من أجل كل $n \in \mathbb{N}$ فإنه يُقال عن هذه المتتالية إنها مُحقق **قانون برنولي للأعداد الكبيرة** Bernoulli's Law of Large Numbers.

(٢, ٢, ٢, ٨) ملاحظة

إذا كانت متتالية المتغيرات العشوائية $(X_n)_{n \in \mathbb{N}}$ لا تملك عزوماً ابتدائية ولا من أية مرتبة، فإن المبرهنة السابقة تصبح عديمة التطبيق، وفي مثل هذه الحالات يلجأ المرء إلى تقنية الدوال المميزة، وهذا ما ستظهره المبرهنة الآتية التي سنقبلها دون برهان أيضاً.

(٦, ٢, ٨) مبرهنة بخصوص تقارب المتتالية $\left(\frac{S_n}{n}\right)_{n \in \mathbb{N}}$ من ثابت حقيقي μ

لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ مستقلة ومتطابقة في التوزيع، فعندئذ من أجل μ ثابت يكون لدينا $\frac{S_n}{n} \xrightarrow{P} \mu$ **إذا وفقط إذا** مُحقق أحد الشرطين الآتين:

١- لدينا:

$$\text{a) } \lim_{n \rightarrow \infty} n \cdot P(|X_1| > n) = 0 \quad \& \quad \text{b) } \lim_{n \rightarrow \infty} \mathbf{E}(X_1 \cdot \mathbf{I}_{\{|X_1| \leq n\}}) = \mu$$

٢- الدالة المميزة $\varphi_{X_n}(t)$ قابلة للمفاضلة في النقطة $t = 0$ من أجل كل $n \in \mathbb{N}$ ، ولدينا:

$$\varphi'_{X_n}(0) = i \cdot \mu \quad ; \quad \forall n \in \mathbb{N}$$

فلاحظ هنا أنه لم يُشترط وجود العزوم لعناصر متتالية المتغيرات العشوائية $(X_n)_{n \in \mathbb{N}}$ لكي يتحقق القانون الضعيف للأعداد الكبيرة.

(٨,٣) نظريات النهاية المركزية

Central Limit Theorems

إنَّ نظريات النهاية المركزية تُعدّ من النظريات المهمّة جداً على صعيد الدراسات العشوائية التطبيقية والنظرية على حد سواء، وعلى وجه الخصوص في مجال الدراسات الإحصائية، وهذه النظريات تعمل تحت شروط متنوعة بحسب الغاية التي تتطلبها المسألة المدروسة، وذلك من أجل حساب احتمالات لحوادث تتعلّق بتجربة عشوائية ما أو استقراء يتعلّق بمجتمع إحصائي ما لدى الدراسات الإحصائية. إنَّ تقنية هذه النظريات تقوم على تعيين دوال التوزيع لمتتالية دوال توزيع لأسرة عدودة من المتغيّرات العشوائية المستقلة. كذلك سنرى أنَّ دراسة نظريات النهاية المركزية مبنية على الصلة الوطيدة ما بين نهايات المتتاليات للدوال المميزة للمتغيّرات العشوائية ونهايات المتتاليات لدوال التوزيع الاحتمالية للمتغيّرات العشوائية، وفي هذا الصدد سنلاحظ أنَّ التوزيع الطبيعي سيلعب دوراً مميّزاً ومركزياً في هذا النوع من الدراسات أيضاً.

في الحقيقة من أهمّ الأسباب التي تدفعنا إلى استخدام نظريات النهاية المركزية هو أنَّه عندما يصبح عدد المتغيّرات العشوائية التي تُنمذج الظاهرة التي قيد الدراسة كبيراً بقدر كاف، وكان لدينا دالة (قياسة) g بهذه المتغيّرات العشوائية، فعندئذ لا يعود اهتمامنا مركّزاً على أن تأخذ هذه الدالة g قيمة محدّدة، وإنّما يتركّز اهتمامنا على أن يكون لهذه الدالة g قيمة في فترة I من \mathbb{R} .

سنقدّم فيما يلي بعض نظريات النهاية المركزية التي سنبدأها بأبسط نموذج منها، ألا وهو نظرية موافير-لابلاس.

(٨,٣,١) مسألة موافير-لابلاس Moivre – Laplace Problem:

إنَّ هذه المسألة تنطلق من حالة خاصّة جداً، وذلك عندما تكون متتالية المتغيّرات العشوائية التي قيد الدراسة مستقلة ومتطابقة في التوزيع مع توزيع متغيّر عشوائي X خاضع لتوزيع برنولي، والنظرية الآتية توضّح لنا ذلك.

(٨,٣,١,١) نظرية موافير-لابلاس Moivre – Laplace Theorem:

لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيّرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، ولنضع ما يلي:

$$Z_n = \frac{S_n - \mathbf{E} S_n}{\sqrt{\text{var } S_n}} \quad ; \forall n \in \mathbb{N} \quad [8,13]$$

علماً أنَّ S_n معطاة بالعلاقة [8,8]، كما نلاحظ هنا أنَّ $\mathbf{E} Z_n = 0$ و $\text{var } Z_n = 1$ من أجل كل $n \in \mathbb{N}$. الآن، إذا كانت المتغيّرات العشوائية $X_1, X_2, \dots, X_n, \dots$ مستقلة وبرنولية بمعلّمة مشتركة $0 < p < 1$ (أي إنّها متطابقة في التوزيع مع توزيع متغيّر عشوائي X خاضع لتوزيع برنولي بمعلّمة $0 < p < 1$)، فعندئذ ستكون العلاقة الآتية محقّقة من أجل أيّة قيمة $z \in \mathbb{R}$:

$$\lim_{n \rightarrow \infty} F_{Z_n}(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{t^2}{2}} dt = \Phi(z) \quad [8,14]$$

البرهان: لنفترض أنَّ φ_{S_n} هي الدالة المميزة للمتغيّر العشوائي S_n من أجل كل $n \in \mathbb{N}$ ، فعندئذ بسبب أنّه للمتغيّر العشوائي S_n توزيعاً حدائياً بمعلّمتين n و p ، فإنّه سينتج من استقلال المتغيّرات العشوائية $X_1, X_2, \dots, X_n, \dots$ العلاقة الآتية:

$$\varphi_{S_n}(t) = \left[1 - p \cdot (1 - e^{it}) \right]^n \quad ; \forall t \in \mathbb{R}$$

ومن ثمّ يكون:

$$\varphi_{Z_n}(t) = \exp \left[\frac{-it \cdot \mathbf{E} S_n}{\sqrt{\text{var } S_n}} \right] \cdot \varphi_{S_n} \left(\frac{t}{\sqrt{\text{var } S_n}} \right)$$

ولكن لدينا:

$$\exp \left[\frac{-it \cdot \mathbf{E} S_n}{\sqrt{\text{var } S_n}} \right] \cdot \varphi_{S_n} \left(\frac{t}{\sqrt{\text{var } S_n}} \right) = \left[(1-p) \cdot \exp \left(\frac{-i p t}{\sqrt{n p (1-p)}} \right) + p \cdot \exp \left(\frac{i t (1-p)}{\sqrt{n p (1-p)}} \right) \right]^n$$

ومن نشر تايلور للدالة e^{it} يمكننا أن نكتب $e^{it} = \sum_{k=0}^n \frac{(it)^k}{k!} + \theta(t^n)$ علماً أن $\theta(t^n)$ مقدار لا متناهي في الصغر من الدرجة n بـ t ، ومن ثم يمكننا من أجل كل $t \in \mathbb{R}$ أن نكتب الآتي:

$$p \cdot \exp \left(\frac{i t (1-p)}{\sqrt{n p (1-p)}} \right) = p + it \sqrt{\frac{p(1-p)}{n}} - \frac{(1-p)t^2}{2n} + \theta \left(\frac{t^2}{n} \right)$$

$$(1-p) \cdot \exp \left(\frac{-i t p}{\sqrt{n p (1-p)}} \right) = (1-p) - it \sqrt{\frac{p(1-p)}{n}} - \frac{p t^2}{2n} + \theta \left(\frac{t^2}{n} \right)$$

علماً أن $\lim_{n \rightarrow \infty} n \cdot \theta \left(\frac{1}{n} t^2 \right) = 0$ ، فلو قمنا الآن بالتعويض في صيغة φ_{Z_n} مع مراعاة أن $p + (1-p) = 1$ فإننا سنحصل على العلاقة الآتية:

$$\varphi_{Z_n}(t) = \left[1 - \frac{t^2}{2n} + \theta \left(\frac{t^2}{n} \right) \right]^n ; \forall t \in \mathbb{R}$$

وبأخذ لوغاريتم الطرفين للعلاقة السابقة يصبح لدينا:

$$\ln \varphi_{Z_n}(t) = n \cdot \ln \left[1 - \frac{t^2}{2n} + \theta \left(\frac{t^2}{n} \right) \right] ; \forall t \in \mathbb{R}$$

وبوضع $\alpha := \frac{-t^2}{2n} + \theta \left(\frac{1}{n} t^2 \right)$ ، وبسبب أن $|\alpha| < 1$ ، ومن ثم نشر الدالة $\ln(1+\alpha)$ ، فإنه من أجل أي $t \in \mathbb{R}$ مثبتة و n كبيرة بقدر كافٍ، ينتج لدينا ما يلي:

$$\ln \varphi_{Z_n}(t) = n \cdot \ln(1+\alpha) = n \cdot \alpha = \frac{-t^2}{2} + n \cdot \theta \left(\frac{t^2}{n} \right)$$

وبأخذ نهاية الطرفين للعلاقة السابقة عندما $n \rightarrow \infty$ نحصل على العلاقة الآتية:

$$\lim_{n \rightarrow \infty} \ln \varphi_{Z_n}(t) = \frac{t^2}{2} ; \forall t \in \mathbb{R}$$

وهذا يعني أن:

$$\lim_{n \rightarrow \infty} \varphi_{Z_n}(t) = e^{\frac{t^2}{2}} ; \forall t \in \mathbb{R}$$

وهذه العلاقة الأخيرة ما هي إلا الدالة المميزة لمتغير عشوائي خاضع للتوزيع الطبيعي المعياري، ومنه بحسب مبرهنة الاستمرار لـ ليفي / ٣-٣-٤-٧/ فإنه سيتبع لدينا العلاقة الآتية التي تنهي برهان المبرهنة:

$$\lim_{n \rightarrow \infty} F_{Z_n}(z) = \Phi(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{t^2}{2}} dt ; \forall t \in \mathbb{R}$$

(٢, ١, ٣, ٨) نتائج

١- إذا كانت n كبيرة بقدر كاف، فعندئذ يمكننا باستخدام النظرية السابقة أن نكتب الآتي من أجل أية قيمتين $z_1, z_2 \in \mathbb{R}$ مع $z_2 > z_1$:

$$P(z_1 < Z_n < z_2) \approx \frac{1}{\sqrt{2\pi}} \int_{z_1}^{z_2} e^{-\frac{t^2}{2}} dt = \Phi(z_2) - \Phi(z_1) \quad [8,15]$$

التي نستنتج منها أن:

$$P(z_1 \sqrt{np(1-p)} + np < S_n < z_2 \sqrt{np(1-p)} + np) \approx \Phi(z_2) - \Phi(z_1)$$

فإذا افترضنا أن:

$$s_1 = z_1 \sqrt{np(1-p)} + np \quad \& \quad s_2 = z_2 \sqrt{np(1-p)} + np \quad (*)$$

فعندئذ سيصبح لدينا:

$$P(s_1 < S_n < s_2) \approx \Phi\left(\frac{s_2 - np}{\sqrt{np(1-p)}}\right) - \Phi\left(\frac{s_1 - np}{\sqrt{np(1-p)}}\right) \quad [8,16]$$

ويقال في هذه الحالة إن S_n **مقارب للتوزيع الطبيعي** Asymptotically Normal Distributed بمتوسط np وانحراف معياري

$$S_n \sim N(np, \sqrt{np(1-p)})$$

٢- بسبب أن $S_n \sim B(n, p)$ فإنه سيكون لدينا:

$$E\bar{\pi}_n = p \quad \& \quad \text{var}\bar{\pi}_n = \frac{p(1-p)}{n} \quad [8,17]$$

ومن ثم سيصبح المتغير العشوائي الآتي معيارياً:

$$Z_n := \frac{\bar{\pi}_n - E\bar{\pi}_n}{\sqrt{\text{var}\bar{\pi}_n}} \quad [8,18]$$

ومن ثم ستتحقق متتالية دوال التوزيع $(F_{Z_n})_{n \in \mathbb{N}}$ نظرية **موافير-لابلاس**، ومنه ينتج لدينا أن:

$$\lim_{n \rightarrow \infty} F_{Z_n}(z) = \Phi(z) \quad ; \quad \forall z \in \mathbb{R}$$

وبناء على ما سبق فإنه من أجل أية قيمتين z_1 و z_2 من \mathbb{R} مع $z_2 > z_1$ يمكننا أن نكتب الآتي:

$$P(z_1 < Z_n < z_2) \approx \Phi(z_2) - \Phi(z_1)$$

ولكن لدينا:

$$P(z_1 < Z_n < z_2) = P\left(z_1 < \frac{\bar{\pi}_n - p}{\sqrt{\frac{p(1-p)}{n}}} < z_2\right) = P\left(z_1 \sqrt{\frac{p(1-p)}{n}} + p < \bar{\pi}_n < z_2 \sqrt{\frac{p(1-p)}{n}} + p\right)$$

فلو وضعنا:

$$\beta_1 = z_1 \sqrt{\frac{p(1-p)}{n}} + p \quad \& \quad \beta_2 = z_2 \sqrt{\frac{p(1-p)}{n}} + p$$

فإنه يصبح لدينا ما يلي:

$$P(\beta_1 < \bar{\pi}_n < \beta_2) \approx \Phi\left(\frac{\beta_2 - p}{\sqrt{\frac{p(1-p)}{n}}}\right) - \Phi\left(\frac{\beta_1 - p}{\sqrt{\frac{p(1-p)}{n}}}\right) \quad [8,19]$$

وفي هذه الحالة يُقال عن المتغير العشوائي $\bar{\pi}_n$ إنه **مقارب للتوزيع الطبيعي** بمتوسط p وانحراف معياري $\sqrt{\frac{p(1-p)}{n}}$ ، وسنكتب ذلك اصطلاحاً على النحو الآتي:

$$\bar{\pi}_n \sim N\left(p, \sqrt{\frac{p(1-p)}{n}}\right)$$

(٨, ٣, ١, ٣) أمثلة

١- لدى تنفيذ استطلاع للرأي حول جودة منتج صناعي طرح سؤال يحتمل إحدى إجابتين فقط (**جيد أو رديء**) على 1000 شخص وبشكل مستقل كل منهم عن الآخر، فإذا افترضنا أن أيّ الإجابتين لها الاحتمال نفسه، فما هو احتمال أن يكون عدد الذين أجابوا بعبارة "جيد" ما بين 525 و 550 شخصاً؟

الحل: من أجل ذلك لنفترض أن X_n متغير عشوائي راصد لإجابة الشخص ذي الرقم n مع $n \in N_{1000}$ فعندئذ نجد أن هذه المتغيرات العشوائية هي متغيرات عشوائية برنولية ومستقلة بمعلّمة مشترك $p = \frac{1}{2}$ (**ومتطابقة في التوزيع أيضاً**)، فلو افترضنا أن عبارة جيد ورديء يقابلها القيمة 1 و 0 على الترتيب، فإنه سيكون لدينا:

$$P(X_n = 1) = P(X_n = 0) = \frac{1}{2}$$

فلو أخذنا S_n من أجل كل $n \in N$ متغير عشوائي مُعطى وفقاً للعلاقة [8,8]، فعندئذ سيكون لـ S_n توزيع حداني $B(1000, \frac{1}{2})$ ، ومن ثمّ ينتج لدينا أن $ES_n = 500$ و $\text{var } S_n = 250$ ، ومن ثمّ يكون الاحتمال المطلوب يساوي:

$$\begin{aligned} P(525 < S_n < 550) &= P\left(\frac{525-500}{\sqrt{250}} < \frac{S_n-500}{\sqrt{250}} < \frac{550-500}{\sqrt{250}}\right) \\ &= P(1.58 < \bar{\pi}_n < 3.16) \approx \Phi(3.16) - \Phi(1.58) \approx 1 - 0.94298 = 0.05702 \end{aligned}$$

علماً أن $\bar{\pi}_n := \frac{S_n - 500}{\sqrt{250}}$ ، وبهذا ينتهي حل المثال.

٢- في بلد قامت إحدى المؤسسات الإعلامية باستطلاع للرأي حول موضوع البطالة، وقد شمل الاستطلاع 75 ألف شخص اختيروا عشوائياً، حيث أجاب 15 ألفاً منهم **بـ "نعم" (أي إنه عاطل عن العمل)**، ومن ثمّ ادعت هذه المؤسسة أن نسبة العاطلين عن العمل تُشكّل 20% من التعداد العام للسكان. لكن الهيئة المسؤولة عن العمل في ذلك البلد شكّكت في هذه النتيجة لاعتقادها أن الاستطلاع لم يشمل عدداً كافياً من الأشخاص. فطلبت من مكتب الإحصاء لديها أن يقوم بحساب عدد الأشخاص n الذي يجب أن يشملهم الاستطلاع حتى تكون نسبة العاطلين عن العمل ما بين 19% و 21% باحتمال قدره 0.95 حيث ستقبل بأن هذه القيمة للاحتمال تعطي مصداقية كافية بقبول العدد n ومن ثمّ مقارنته مع عدد الأشخاص الذين شملهم الاستطلاع لاتخاذ قرار القبول أو الرفض.

الحل: للإجابة على هذا الطلب سنفترض X_k متغير عشوائي راصد لنتيجة جواب الشخص ذي الرقم k مع $k \in N_n$ ، فعندئذ نجد أن هذه المتغيرات العشوائية هي متغيرات عشوائية برنولية مستقلة مع $P(X_n = 0) = 0.80$ و $P(X_n = 1) = 0.20$ ،

حيث لدينا هنا النجاح هو الحصول على شخص عاطل عن العمل، وآخذين في الحسبان أن نسبة العاطلين عن العمل تشكل 20% من التعداد العام للسكان وفقاً للاستطلاع الذي تم، ومن ثم يكون لهذه المتغيرات العشوائية معلمة مشترك $p = 0.20$ (وهذه المتغيرات العشوائية متطابقة في التوزيع أيضاً).

الآن لو أخذنا من أجل كل $n \in \mathbb{N}$ المتغيرين العشوائيين S_n و $\bar{\pi}_n$ المعطيين بالعلاقتين [8,8] و [8,11-b] على الترتيب، فعندئذ يمثل المتغير العشوائي $\bar{\pi}_n$ التكرار النسبي للعاطلين عن العمل، ومن ثم يكون لدينا:

$$E \bar{\pi}_n = \frac{1}{n} E S_n = \frac{n p}{n} = p = 0.20$$

$$\text{var } \bar{\pi}_n = \frac{1}{n^2} \text{var } S_n = \frac{n p (1-p)}{n^2} = \frac{p (1-p)}{n} = \frac{0.16}{n}$$

ولكن من الفرض لدينا:

$$\begin{aligned} 0.95 = P(0.19 < \bar{\pi}_n < 0.21) &= P\left(\frac{0.19-0.20}{\sqrt{\frac{0.16}{n}}} < \frac{\bar{\pi}_n - 0.20}{\sqrt{\frac{0.16}{n}}} < \frac{0.21-0.20}{\sqrt{\frac{0.16}{n}}}\right) \\ &= P\left(-0.25 \sqrt{n} < \frac{\bar{\pi}_n - 0.20}{\sqrt{\frac{0.16}{n}}} < 0.25 \sqrt{n}\right) \approx \frac{1}{\sqrt{2\pi}} \int_{-0.25\sqrt{n}}^{0.25\sqrt{n}} e^{-\frac{t^2}{2}} dt \end{aligned}$$

وبوضع $z = 0.25\sqrt{n}$ يصبح لدينا:

$$\frac{1}{\sqrt{2\pi}} \int_{-z}^z e^{-\frac{t^2}{2}} dt = 2 \frac{1}{\sqrt{2\pi}} \int_0^z e^{-\frac{t^2}{2}} dt = 2(\Phi(z) - 0.5)$$

ومن ثم يكون $\Phi(z) - 0.5 = 0.475$ ، وبالتالي ينتج أن $\Phi(z) = 0.975$ ، وباستخدام جدول التوزيع الطبيعي المعياري نجد أن قيمة z تساوي 1.96، ومنه يكون لدينا $0.25\sqrt{n} = 1.96$ والتي نحصل منها على حجم العينة المفترض سحبها $n \approx 61.466$ ، ومن ثم يجب أن يكون عدد الأشخاص الذين يشملهم الاستطلاع لا يقل عن 61466 شخصاً، وهو أقل من العدد الذي تم سبره في استطلاع الرأي، ومن ثم فليس أمام الهيئة المسؤولة عن العمل من خيار إلا القبول بنتائج هذا الاستطلاع.

(٨, ٣, ٢) مسألة ليندنبرغ – ليفي Lindenberg – Levy Problem

إن هذه المسألة تنطلق من حالة أقل خصوصية من سابقتها وذلك عندما تكون متتالية المتغيرات العشوائية المستقلة متطابقة في التوزيع ولكن ليس بالضرورة أن تكون برنولية التوزيع، ومقابل ذلك التعميم ستظهر لدينا قيوداً إضافية توضحها لنا المبرهنة التي سنقدمها بعد التمهيد الآتي.

(٨, ٣, ٢, ١) تمهيد

لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ مستقلة ومتطابقة التوزيع مع توزيع متغير عشوائي X ، وتملك عزوماً ابتدائية من المرتبة الثانية، ولنفترض أنه من أجل كل $n \in \mathbb{N}$ لدينا:

$$\mathbf{E} X_n = \mathbf{E} X = \mu \quad \& \quad \mathbf{var} X_n = \mathbf{var} X = \sigma^2$$

فلو أخذنا S_n من أجل كل $n \in \mathbb{N}$ متغير عشوائي معطى وفقاً للعلاقة [8,8]، فعندئذ سيكون من أجل كل $n \in \mathbb{N}$ لدينا:

$$\mathbf{E} S_n = n \cdot \mu \quad \& \quad \mathbf{var} S_n = n \cdot \sigma^2$$

ولنقم باستيعار المتغيرات العشوائية S_n باستخدام العلاقة [8,13] فيكون لدينا:

$$Z_n := \frac{S_n - \mathbf{E} S_n}{\sqrt{\mathbf{var} S_n}} = \frac{S_n - n \cdot \mu}{\sigma \cdot \sqrt{n}} \quad ; \forall n \in \mathbb{N} \quad [8,20]$$

توضح لنا النظرية الآتية أن متتالية دوال التوزيع $(F_{Z_n})_{n \in \mathbb{N}}$ للمتغيرات العشوائية المعرفة بالعلاقة السابقة [8,20] ستكون متقاربة من دالة التوزيع الطبيعي المعياري Φ .

(٨, ٣, ٢, ٢) نظرية ليندبرغ-ليفلي **Lindenberg-Levy Theorem**

لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ مستقلة ومتطابقة التوزيع مع توزيع متغير عشوائي X ، وتملك عزوماً ابتدائية من المرتبة الثانية مع:

$$\mathbf{E} X_n = \mathbf{E} X = \mu \quad \& \quad \mathbf{var} X_n = \mathbf{var} X = \sigma^2 > 0 \quad ; \forall n \in \mathbb{N}$$

ولتكن $(Z_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية عناصرها معرفة بالعلاقة [8,20]، ولنفترض أن $F_{Z_1}, F_{Z_2}, \dots, F_{Z_n}, \dots$ هي متتالية دوال التوزيع الاحتمالية للمتغيرات العشوائية $Z_1, Z_2, \dots, Z_n, \dots$ على الترتيب، فعندئذ ستكون العلاقة الآتية محققة:

$$\lim_{n \rightarrow \infty} F_{Z_n}(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{t^2}{2}} dt = \Phi(z) \quad ; \forall n \in \mathbb{N} \quad [8,21]$$

البرهان: بحسب معطيات المسألة يمكننا أن نكتب من أجل كل $n \in \mathbb{N}$ ما يلي:

$$Z_n = \frac{S_n - \mathbf{E} S_n}{\sqrt{\mathbf{var} S_n}} = \frac{S_n - n \cdot \mu}{\sigma \cdot \sqrt{n}} = \frac{1}{\sigma \sqrt{n}} \sum_{i=1}^n (X_i - \mu)$$

وبسبب تطابق التوزيع للمتغيرات العشوائية X_n مع توزيع X سيتبع أن لجميع المتغيرات العشوائية $X_n^* = X_n - \mu$ توزيع متطابق مع توزيع المتغير العشوائي $X^* = X - \mu$ ، وكذلك لدينا:

$$\mathbf{E} X_n^* = \mathbf{E} X^* = 0 \quad \& \quad \mathbf{var} X_n^* = \mathbf{var} X^* = \sigma^2 \quad ; \forall n \in \mathbb{N}$$

ومن ثم دوال توزيع المتغيرات العشوائية X_n^* ستتطابق مع دالة التوزيع F_{X^*} من أجل كل $n \in \mathbb{N}$ ، والتي لها دالة مميزة φ_{X^*} نفسها كالتي للمتغيرات العشوائية X_n^* من أجل كل $n \in \mathbb{N}$ أيضاً، ومن ثم يمكننا أن نكتب الآتي:

$$\varphi_{Z_n}(t) = \left(\varphi_{X^*} \left(\frac{t}{\sigma \sqrt{n}} \right) \right)^n \quad ; \forall t \in \mathbb{R}$$

وبنشر الدالة $\varphi_{X^*}(t)$ في جوار الصفر وفقاً لـ **لنشر ماكلوران** Maclaurin Expansion نجد:

$$\varphi_{X^*}(t) = 1 - \frac{1}{2} \sigma^2 t^2 + \theta(t^2) \quad ; \forall t \in \mathbb{R}$$

وبالتعويض في صيغة $\varphi_{Z_n}(t)$ يصبح لدينا ما يلي:

$$\varphi_{Z_n}(t) = \left[1 - \frac{t^2}{2n} + \theta \left(\frac{t^2}{n} \right) \right]^n \quad ; \forall t \in \mathbb{R}$$

علماً أنه من أجل كل $t \in \mathbb{R}$ لدينا $\lim_{n \rightarrow \infty} n \cdot \theta\left(\frac{1}{n}t^2\right) = 0$ ، ومن ثمَّ بوضع: $\tilde{\theta} := -\frac{1}{2n}t^2 + \theta\left(\frac{1}{n}t^2\right)$ نجد أنَّ:

$$\log \varphi_{Z_n}(t) = n \cdot \log(1 + \tilde{\theta}) = n \cdot \left[-\frac{t^2}{2n} + \theta\left(\frac{t^2}{n}\right) \right] = -\frac{t^2}{2} + n \cdot \theta\left(\frac{t^2}{n}\right)$$

وبأخذ نهاية الطرفين عندما n تسعى إلى اللانهاية يصبح لدينا:

$$\lim_{n \rightarrow \infty} \log \varphi_{Z_n}(t) = -\frac{t^2}{2}$$

والتي ينتج عنها أنَّ:

$$\lim_{n \rightarrow \infty} \varphi_{Z_n}(t) = e^{-\frac{t^2}{2}}$$

ولكن الطرف الأيمن من العلاقة الأخيرة هي الدالة المميزة لمتغير عشوائي خاضع للتوزيع الطبيعي المعياري، ومن ثمَّ باستخدام مبرهنة الاستمرار لـ ليفي (٣، ٣، ٤، ٧) ينتج لدينا أنَّ:

$$\lim_{n \rightarrow \infty} F_{Z_n}(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{t^2}{2}} dt \quad ; \forall z \in \mathbb{R}$$

وبهذا يتم البرهان.

(٣، ٢، ٣، ٨) تطبيق

لنأخذ z_1 و $z_2 \in \mathbb{R}$ مع $z_2 > z_1$ ، ولنفترض أنَّه من أجل كل $n \in \mathbb{N}$ لدينا Z_n معطاة كما في العلاقة [8,20]، فعندئذ يكون لدينا:

$$\lim_{n \rightarrow \infty} P(z_1 < Z_n < z_2) = \lim_{n \rightarrow \infty} (F_{Z_n}(z_2) - F_{Z_n}(z_1)) = \frac{1}{\sqrt{2\pi}} \int_{z_1}^{z_2} e^{-\frac{t^2}{2}} dt$$

ولكن لدينا:

$$P(z_1 < Z_n < z_2) = P\left(z_1 < \frac{S_n - n \cdot \mu}{\sigma \sqrt{n}} < z_2\right) = P(z_1 \sigma \sqrt{n} + n \cdot \mu < S_n < z_2 \sigma \sqrt{n} + n \cdot \mu)$$

وبوضع:

$$s_1 = z_1 \sigma \sqrt{n} + n \cdot \mu \quad \& \quad s_2 = z_2 \sigma \sqrt{n} + n \cdot \mu \quad (**)$$

يصبح لدينا ما يلي:

$$\lim_{n \rightarrow \infty} P(s_1 < S_n < s_2) = \frac{1}{\sqrt{2\pi}} \int_{z_1}^{z_2} e^{-\frac{t^2}{2}} dt$$

وهذا يعني أنَّه من أجل n كبيرة بقدر كافٍ يمكننا أن نكتب:

$$P(s_1 < S_n < s_2) \approx \frac{1}{\sqrt{2\pi}} \int_{z_1}^{z_2} e^{-\frac{t^2}{2}} dt$$

علماً أنَّ z_1 و z_2 تحسبان بوساطة العلاقتين في (**).

(٤, ٢, ٣, ٨) ملاحظات:

١- لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ مستقلة ومتطابقة بالتوزيع، وتملك عزوماً ابتدائية من المرتبة الثانية. عندئذ يُقال عن المتغيرات العشوائية S_n (المُعطاة في هذه الفقرة) إنها **مقاربة للتوزيع الطبيعي** بمتوسط $n \cdot \mu$ وانحراف معياري $\sigma \sqrt{n}$ علماً أنَّ $N \ni n$ ، وسنكتب ذلك اصطلاحاً بالشكل $S_n \sim N(n\mu, \sigma \sqrt{n})$.

٢- إذا كان المجموع لمتغيرات عشوائية مستقلة **مقارب للتوزيع الطبيعي**، فعندئذ يُقال إنَّ نظرية النهاية المركزية مُحَقَّقة من أجل هذا المجموع، ومن ثمَّ فإنَّ المتغيرات العشوائية S_n لكل $N \ni n$ (والمُعطاة سابقاً في هذه الفقرة) ستَحَقِّق من أجلها نظرية النهاية المركزية.

(٥, ٢, ٣, ٨) أمثلة:

١- لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية مستقلة ومتطابقة في التوزيع مع توزيع متغير عشوائي برنولي X بمعلمة $0 < p < 1$ ، أي إنَّه من أجل كل $N \ni n$ لدينا ما يلي:

$$P(X_n = 1) = P(X = 1) = p \quad \& \quad P(X_n = 0) = P(X = 0) = 1 - p$$

فعندئذ سيكون المتغير العشوائي $S_n = \sum_{i=1}^n X_i$ خاضع للتوزيع الحداني بمعلمتين n و p من أجل كل $N \ni n$ ، ومن جهة أخرى لدينا من أجل كل $N \ni n$ الآتي مُحَقَّقاً:

$$EX_n = p \quad \& \quad \text{var } X_n = p(1-p)$$

أي إنَّه من أجل كل $N \ni n$ سيكون لـ X_n تباين وتوقع رياضياتي متناه، ومن ثمَّ تكون شروط استخدام نظرية النهاية المركزية لـ ليندبرغ-ليففي من أجل المتغيرات العشوائية S_n مُحَقَّقاً، علماً أنَّه لدينا $S_n \sim N(np, \sqrt{np(1-p)})$ ، ومن هذه النتيجة يتبيَّن لنا أنَّ مسألة موافير-لابلاس ما هي إلاَّ حالة خاصة من مسألة ليندبرغ-ليففي.

٢- لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية مستقلة ومتطابقة في التوزيع مع توزيع متغير عشوائي بواسوني بمعلمة $0 < \lambda$ فعندئذ من أجل كل $N \ni n$ سيكون لدينا $EX_n = \lambda$ و $\text{var } X_n = \lambda$ ، وكذلك:

$$P(X_n = k) = \frac{\lambda^k}{k!} e^{-\lambda} \quad ; \quad k \in \mathbb{N}^0$$

ولنأخذ S_n كما في العلاقة [8,8]، فيكون لدينا:

$$ES_n = \sum_{i=1}^n EX_i = n \cdot \lambda \quad \& \quad \text{var } S_n = \sum_{i=1}^n \text{var } X_i = n \cdot \lambda$$

ولنقم بحساب الاحتمال $P(190 < S_{100} < 210)$ من أجل $\lambda = 2$.

الحل: بملاحظة أنَّ فرضيات مبرهنة ليندبرغ-ليففي مُحَقَّقة من أجل المسألة المُعطاة، ولذلك يمكننا أن نكتب الآتي:

$$P(190 < S_{100} < 210) = P\left(\frac{190-200}{10\sqrt{2}} < \frac{S_{100}-200}{10\sqrt{2}} < \frac{210-200}{10\sqrt{2}}\right) = P(-0.71 < Z_{100} < 0.71) \\ \approx \Phi(0.71) - \Phi(-0.71) = 0.7611 - 0.2389 = 0.5222$$

علماً أنَّ $Z_{100} := \frac{S_{100} - 200}{10\sqrt{2}}$ ، وبهذا يتمُّ الحل.

تعرض لنا النتيجة الآتية إحدى أهم النتائج لنظرية ليندبرغ-ليففي.

(٦, ٢, ٣, ٨) نتيجة

لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ مستقلة ومتطابقة بالتوزيع مع توزيع متغير عشوائي X ، وعناصرها تملك عزوماً ابتدائية من المرتبة الثانية مع:

$$\mathbf{E}X_n = \mathbf{E}X = \mu \quad \& \quad \mathbf{var} X_n = \mathbf{var} X = \sigma^2 > 0$$

ولنأخذ متتالية المتغيرات العشوائية $(\bar{X}_n)_{n \in \mathbb{N}}$ علماً أنّ \bar{X}_n معطى بالعلاقة [8,11-a]، فعندئذ تكون المتتالية $(\bar{X}_n)_{n \in \mathbb{N}}$ مقارنة

للتوزيع الطبيعي بمتوسط μ وانحراف معياري $\frac{\sigma}{\sqrt{n}}$ ، أي إنّ $\bar{X}_n \sim N\left(\mu, \frac{\sigma}{\sqrt{n}}\right)$.

الإثبات: بملاحظة أنّه من أجل كل $n \in \mathbb{N}$ يمكننا أن نكتب الآتي:

$$\mathbf{E}\bar{X}_n = \frac{n\mu}{n} = \mu \quad \& \quad \mathbf{var} \bar{X}_n = \frac{n \cdot \sigma^2}{n^2} = \frac{\sigma^2}{n}$$

وكذلك بوضع:

$$Z_n = \frac{\bar{X}_n - \mathbf{E}\bar{X}_n}{\sqrt{\mathbf{var} \bar{X}_n}} = \frac{\frac{1}{n} \sum_{i=1}^n X_i - \mu}{\frac{\sigma}{\sqrt{n}}} = \frac{\sum_{i=1}^n X_i - n\mu}{\sigma \sqrt{n}}$$

فإنّه بحسب الملاحظة ١ / من (٤, ٢, ٣, ٨) ستكون المتتالية $(\bar{X}_n)_{n \in \mathbb{N}}$ مقارنة للتوزيع الطبيعي بمتوسط μ وانحراف معياري $\frac{\sigma}{\sqrt{n}}$ ، وبهذا يتم الإثبات.

(٧, ٢, ٣, ٨) أمثلة

١- لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية مستقلة ومتطابقة بالتوزيع مع متغير عشوائي X خاضع للتوزيع المنتظم المتقطع بقيم في \mathbb{N}_9^0 ، ولننظر ما الذي يحدث لقيمة الاحتمال المتعلق بالمتوسط \bar{X}_n عندما نبتعد عن القيمة المتوقعة لـ X_n وذلك من أجل قيم مثبتة لـ $n \in \mathbb{N}$.

الحل: لدينا من أجل كل $n \in \mathbb{N}$ ما يلي:

$$P(X = k) = 0.1 \quad ; \forall k \in \mathbb{N}_9^0$$

وكذلك:

$$\mathbf{E}X_n = \frac{1}{10} \sum_{k=0}^9 k = 4.5 = \mu \quad \& \quad \mathbf{var} X_n = \frac{1}{10} \sum_{k=0}^9 (k - \mu)^2 = 8.25 = \sigma^2$$

وبناءً على النتيجة السابقة يكون لدينا $\bar{X}_n \sim N\left(4.5, \frac{2.87}{\sqrt{n}}\right)$ ، فلو أخذنا على سبيل المثال قيمة مثبتة لـ n ولتكن $n = 25$ ، فعندئذ سيكون $\bar{X}_{25} \sim N\left(4.5, \frac{2.87}{5}\right)$ ، ومن ثمّ يمكننا أن نكتب:

$$P(\bar{X}_{25} > 5) = P\left(\frac{\bar{X}_{25} - 4.5}{0.574} > \frac{5 - 4.5}{0.574}\right) = 1 - P\left(\frac{\bar{X}_{25} - 4.5}{0.574} \leq 0.87\right) \\ \approx 1 - \Phi(0.87) = 1 - 0.8078 = 0.1922$$

وبالمثل نجد أنّ:

$$P(\bar{X}_{25} > 5.5) = P\left(\frac{\bar{X}_{25} - 4.5}{0.574} > \frac{5.5 - 4.5}{0.574}\right) = 1 - P\left(\frac{\bar{X}_{25} - 4.5}{0.574} \leq 1.74\right) \\ \approx 1 - \Phi(1.74) = 1 - 0.9591 = 0.04090$$

وهكذا فإنه من أجل قيمة مُشَبَّهة $n \in \mathbb{N}$ نلاحظ أنه كلما ابتعدت قيمة المتوسط \bar{X}_n عن القيمة المتوقعة لـ X ، تناقصت قيمة الاحتمال للحدث المدروس، وإحصائياً لو كانت \bar{x}_n (قيمة \bar{X}_n) هي متوسط قيم بيانات عينة حجمها n ، وكان X واصفاً لمجتمع إحصائي متوسطه μ ، فإن أفضل النتائج لهذه العينة نحصل عليها من أجل $\mu = EX = \bar{x}_n$.

الآن لنأخذ قيمة أخرى لـ n (مع ثبات قيمة الانحراف المعياري والمتوسط) ولننظر إن كان ذلك سيؤدي إلى تغير في النتائج أم لا؟

أ- من أجل $n = 64$ لدينا $\bar{X}_{64} \sim N\left(4.5, \frac{2.87}{8}\right)$ ، ومن ثم يمكننا أن نكتب:

$$P(\bar{X}_{64} > 5) = P\left(\frac{\bar{X}_{64} - 4.5}{0.359} > \frac{5 - 4.5}{0.359}\right) = 1 - P\left(\frac{\bar{X}_{64} - 4.5}{0.359} \leq 1.39\right) \\ \approx 1 - \Phi(1.39) = 1 - 0.9177 = 0.0823$$

وبالمثل نجد أن:

$$P(\bar{X}_{64} > 5.5) = P\left(\frac{\bar{X}_{64} - 4.5}{0.359} > \frac{5.5 - 4.5}{0.359}\right) = 1 - P\left(\frac{\bar{X}_{64} - 4.5}{0.359} \leq 2.89\right) \\ \approx 1 - \Phi(2.89) = 1 - 0.9981 = 0.0019$$

فنلاحظ أن قيم الاحتمالات قد تناقصت بزيادة قيمة n .

ب- لنأخذ الآن قيمة n تساوي 100، فعندئذ يكون $\bar{X}_{100} \sim N\left(4.5, \frac{2.87}{10}\right)$ ، ومن ثم يمكننا أن نكتب:

$$P(\bar{X}_{100} > 5) = P\left(\frac{\bar{X}_{100} - 4.5}{0.287} > \frac{5 - 4.5}{0.287}\right) = 1 - P\left(\frac{\bar{X}_{100} - 4.5}{0.287} \leq 1.74\right) \\ \approx 1 - \Phi(1.74) = 1 - 0.9591 = 0.04090$$

وبالمثل نجد أن:

$$P(\bar{X}_{100} > 5.5) = P\left(\frac{\bar{X}_{100} - 4.5}{0.287} > \frac{5.5 - 4.5}{0.287}\right) = 1 - P\left(\frac{\bar{X}_{100} - 4.5}{0.287} \leq 3.48\right) \\ \approx 1 - \Phi(3.48) = 1 - 0.9997 = 0.00030$$

وهكذا نلاحظ أن احتمال ابتعاد قيمة المتوسط عن القيمة المتوقعة لـ X_n تناقصت أكثر فأكثر كلما كبرت قيمة $n \in \mathbb{N}$ أيضاً، ومن ثم فكلما كبرت قيمة $n \in \mathbb{N}$ فإن ابتعاد قيمة المتوسط \bar{X}_n عن القيمة المتوقعة لـ X تؤدي إلى تناقص قيمة الاحتمال للحدث المدروس أكثر فأكثر، وإحصائياً يعني ذلك أنه كلما كبر حجم العينة $n \in \mathbb{N}$ ، تكشفنا لنا حقائق ومعلومات إضافية تقربنا أكثر من سلوك المجتمع المدروس، ومن ثم تكون نتائج دراسة هذه العينة أفضل.

٢- لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية مستقلة ومتطابقة التوزيع مع متغير عشوائي X خاضع للتوزيع المنتظم المستمر على الفترة $[0, 1]$ ، والمطلوب حساب احتمال أن يكون للمتوسط \bar{X}_n قيمة أصغر من $\mu = EX$ ، وذلك من أجل قيم مختلفة لـ $n \in \mathbb{N}$.

الحل: لدينا من أجل كل $n \in \mathbb{N}$ القيم الآتية:

$$\mathbf{E}X_n = \mathbf{E}X = \frac{1}{2} = \mu \quad \& \quad \mathbf{var}X_n = \mathbf{var}X = \frac{1}{12}$$

وبناءً على النتيجة السابقة يكون $\bar{X}_n \sim N\left(\mu, \frac{\sigma}{\sqrt{n}}\right)$ ، فلو أخذنا $n = 49$ فعندئذ يكون لدينا:

$$\bar{X}_{49} = \frac{X_1 + X_2 + \dots + X_{49}}{49}$$

ومن ثم يكون لدينا $\bar{X}_{49} \sim N\left(\frac{1}{2}, \frac{0.2887}{7}\right)$ ، ولنقم بحساب الاحتمالين الآتين:

$$P(\bar{X}_{49} < 0.45) = ? \quad \& \quad P(\bar{X}_{49} < 0.40) = ?$$

لحساب الاحتمال $P(\bar{X}_{49} < 0.45)$ نجد ما يلي:

$$\begin{aligned} P(\bar{X}_{49} < 0.45) &= P\left(\frac{\bar{X}_{49} - 0.5}{0.041} < \frac{0.45 - 0.5}{0.041}\right) \\ &= P\left(\frac{\bar{X}_{49} - 0.5}{0.041} < -1.22\right) \approx \Phi(-1.22) \approx 0.1112 \end{aligned}$$

وأما لحساب الاحتمال $P(\bar{X}_{49} < 0.40)$ نجد بأسلوب مماثل لما سبق ما يلي:

$$P(\bar{X}_{49} < 0.4) = P\left(\frac{\bar{X}_{49} - 0.5}{0.041} < \frac{0.4 - 0.5}{0.041}\right) \approx \Phi(-2.43) \approx 0.0075$$

وأما لو أخذنا الآن $n = 96$ فعندئذ سيكون لدينا $\bar{X}_{96} \sim N\left(\frac{1}{2}, \frac{0.2887}{\sqrt{96}}\right)$ ، ومن ثم يكون لدينا:

$$\begin{aligned} P(\bar{X}_{96} < 0.45) &= P\left(\frac{\bar{X}_{96} - 0.5}{0.0295} < \frac{0.45 - 0.5}{0.0295}\right) \\ &= P\left(\frac{\bar{X}_{96} - 0.5}{0.0295} < -1.69\right) \approx \Phi(-1.69) \approx 0.0455 \end{aligned}$$

وأما لحساب الاحتمال $P(\bar{X}_{96} < 0.40)$ فنجد بأسلوب مماثل لما سبق ما يلي:

$$P(\bar{X}_{96} < 0.4) = P\left(\frac{\bar{X}_{96} - 0.5}{0.0295} < \frac{0.4 - 0.5}{0.0295}\right) \approx \Phi(-3.39) = 0.0003$$

وهكذا نلاحظ أن المناقشة التي قُدمت في المثال السابق (بخصوص تناقص قيمة الاحتمال كلما ابتعدت قيمة المتوسط عن القيمة المتوقعة لـ X_n مع $n \in \mathbb{N}$) تبقى سارية المفعول من أجل هذا المثال أيضاً.

(٩، ٢، ٣، ٨) ملاحظات

- ١- في الواقع إن النتيجة السابقة (بخصوص تناقص قيمة الاحتمال كلما ابتعدت قيمة المتوسط عن القيمة المتوقعة لـ X_n) تبقى سارية المفعول على كل المتغيرات العشوائية التي تملك عزوماً ابتدائية من المرتبة الثانية **عدا** المتغيرات العشوائية الخاضعة للتوزيع الوحيد النقطة.
- ٢- إذا كانت $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية مستقلة ومتطابقة في التوزيع ولكنها لا تملك عزوماً ابتدائية فعندئذ تصبح مبرهنة ليندبرغ-ليفني غير قابلة للتطبيق على هذه المتتالية، ومن ثم يجب البحث في منحى آخر للتعامل مع توزيع المتوسط \bar{X}_n (غالباً باستخدام الدوال المميزة).

Lyapunov Problem (٨, ٣, ٣)

لقد بينا سابقاً من خلال مسألة موافير-لابلاس و ليندنبيرغ-ليفى أنه إذا كانت $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية مستقلة ومتطابقة في التوزيع، فإن دالة توزيع المجموع هذه المتغيرات العشوائية سوف تسعى إلى دالة التوزيع الطبيعي المعياري. لكن إذا كانت هذه المتغيرات العشوائية ليست متطابقة في التوزيع، فعندئذ ليس بالضرورة أن تسعى دالة توزيع المجموع هذه المتغيرات العشوائية إلى التوزيع الطبيعي، ولكن إذا فرضت شروط محددة على متتالية المتغيرات العشوائية المستقلة فحينئذ قد يصبح الوصول إلى تقريب للتوزيع الطبيعي ممكناً. إن نظرية ليابانوف الآتية تقدم لنا الشروط الكافية لكي يتقارب مجموع متغيرات عشوائية مستقلة (حتى لو كانت غير متطابقة في التوزيع) من التوزيع الطبيعي.

Lyapunov Theorem (٨, ٣, ٣, ٢)

لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية مستقلة، وتملك عزوماً ابتدائية من المرتبة الثالثة، وبفرض أن:

$$B_n := \sqrt[3]{\sum_{k=1}^n \beta_k} \quad \& \quad C_n := \sqrt{\sum_{k=1}^n \sigma_k^2} \quad \& \quad Z_n := \frac{\sum_{k=1}^n (X_k - \mu_k)}{C_n}$$

علماً أنه من أجل كل $N \ni k$ لدينا $\mu_k = EX_k$ و $\sigma_k^2 = \text{var } X_k > 0$.

الآن إذا كانت $\lim_{n \rightarrow \infty} \frac{B_n}{C_n}$ موجودة وتحقق العلاقة الآتية:

$$\lim_{n \rightarrow \infty} \frac{B_n}{C_n} = 0 \quad [8,22]$$

فعندئذ من أجل كل $R \ni z$ ستكون العلاقة الآتية محققة:

$$\lim_{n \rightarrow \infty} F_{Z_n}(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{t^2}{2}} dt$$

البرهان: على سبيل تبسيط العمل سنضع من أجل كل $N \ni k$ ما يلي:

$$X_k^* := X_k - \mu_k \quad \& \quad Y_k := \frac{X_k^*}{C_k}$$

وبما أن $EX_k^* = 0$ وكذلك العزوم σ_k^2 و $\mu_k^{(3)}$ موجودة، فإنه يمكن كتابة الآتي:

$$\varphi_{X_k^*}(t) = 1 - \frac{\sigma_k^2 t^2}{2} + \frac{\mu_k^{(3)}}{6} (it)^3 + \theta(\mu_k^{(3)} t^3)$$

ومن ثم فإنه من أجل كل $R \ni t$ سيكون:

$$\varphi_{Y_k}(t) = \varphi_{X_k^*}\left(\frac{t}{C_n}\right) = 1 - \underbrace{\frac{\sigma_k^2 t^2}{2C_n^2} + \frac{\mu_k^{(3)}}{6C_n^3} (it)^3 + \theta\left(\frac{\mu_k^{(3)} t^3}{C_n^3}\right)}_{u_{k,n}} = 1 + u_{k,n}$$

علماً أنه من أجل كل عدد منته $R \ni t$ لدينا ما يلي:

$$\lim_{n \rightarrow \infty} \frac{C_n^3}{\mu_k^{(3)} t^3} \theta\left(\frac{\mu_k^{(3)} t^3}{C_n^3}\right) = 0 \quad (1)$$

ولكن بحسب متباينة ليابانوف العلاقة [7-20] من $1, 2, 3, \dots, 7$ سيكون $\sigma_k \leq \sqrt[3]{\beta_k^{(3)}}$ ، ومن ثم بحسب الشرط [8-22] ينتج أنه من أجل قيمة منتهية $t \in \mathbb{R}$ ستكون المتباينة الآتية محققة:

$$\lim_{n \rightarrow \infty} \left| \frac{-\sigma_k^2 \cdot t^2}{2C_n^2} \right| \leq \lim_{n \rightarrow \infty} \frac{\sqrt[3]{(\beta_k^{(3)})^2}}{2C_n^2} t^2 \leq \lim_{n \rightarrow \infty} \frac{1}{2} \left(\frac{B_n^2}{C_n^2} t^2 \right) = 0$$

ومن ثم يصبح لدينا:

$$\lim_{n \rightarrow \infty} \left| \frac{\mu_k^{(3)} (it)^3}{6C_n^3} \right| \leq \lim_{n \rightarrow \infty} \frac{\beta_k^{(3)}}{6C_n^3} |t|^3 \leq \lim_{n \rightarrow \infty} \frac{B_n^3}{6C_n^3} |t|^3 = 0$$

ومنه ينتج أن $\lim_{n \rightarrow \infty} u_{k,n} = 0$ ، وبسبب التقارب المنتظم لمتتالية الدوال $(u_{k,n})_{n \in \mathbb{N}}$ بالنسبة إلى k ، فإنه من أجل كل $t \in \mathbb{R}$ مثبتة يوجد عدد طبيعي $N = N(t)$ بحيث إنه من أجل كل القيم $N < n$ وكل $n \geq k$ يكون لدينا $|u_{k,n}| > \frac{1}{2}$ ، ومن ثم نحصل على العلاقة الآتية:

$$\begin{aligned} \log \varphi_{Y_k}(t) &= \log(1 + u_{k,n}) = \frac{u_{k,n}}{1} - \frac{u_{k,n}^2}{2} + \frac{u_{k,n}^3}{3} - \frac{u_{k,n}^4}{4} + \dots + (-1)^\ell \frac{u_{k,n}^\ell}{\ell} + \dots \\ &= u_{k,n} - \frac{u_{k,n}^2}{2} \left(1 - \frac{2}{3} u_{k,n} + \frac{2}{4} u_{k,n}^2 - \dots \right) \end{aligned}$$

وبوضع $V_{k,n} = 1 - \frac{2}{3} u_{k,n} + \frac{2}{4} u_{k,n}^2 - \dots$ تنتج المساواة الآتية:

$$\log \varphi_{Y_k}(t) = u_{k,n} - \frac{u_{k,n}^2}{2} V_{k,n}$$

ولكن بسبب أن $|u_{k,n}| > \frac{1}{2}$ فإنه يمكن كتابة الآتي:

$$|V_{k,n}| \leq 1 + \frac{2}{3} |u_{k,n}| + \frac{2}{4} |u_{k,n}|^2 + \dots < 1 + |u_{k,n}| + |u_{k,n}|^2 + \dots < 1 + \frac{1}{2} + \left(\frac{1}{2}\right)^2 + \left(\frac{1}{2}\right)^3 + \dots = \sum_{s=0}^{\infty} \left(\frac{1}{2}\right)^s = 2$$

وبوضع $U_{k,n} = -\frac{V_{k,n}}{2}$ ينتج أن $|U_{k,n}| > 1$ ، ومن ثم يكون لدينا:

$$\log \varphi_{Y_k}(t) = u_{k,n} + u_{k,n}^2 U_{k,n}$$

والآن من أجل كل $n \in \mathbb{N}$ سنضع $Z_n = \sum_{k=1}^n Y_k$ ، وبسبب الاستقلال بين المتغيرات العشوائية Y_1, Y_2, \dots, Y_n فإنه من أجل كل $t \in \mathbb{R}$ ستكون العلاقة الآتية محققة:

$$\varphi_{Z_n}(t) = \prod_{k=1}^n \varphi_{Y_k}(t) \quad (2)$$

ومنه ينتج لدينا:

$$\log \varphi_{Z_n}(t) = \sum_{k=1}^n \log \varphi_{Y_k}(t) = \sum_{k=1}^n \left(u_{k,n} + u_{k,n}^2 U_{k,n} \right)$$

وإضافة لذلك لدينا:

$$\sum_{k=1}^n u_{k,n} = -\frac{t^2}{2} + \sum_{k=1}^n \frac{\mu_k^{(3)}(\mathbf{i} t)^3}{6C_n^3} + \sum_{k=1}^n \theta \left(\frac{\mu_k^{(3)} t^3}{C_n^3} \right) \quad (3)$$

ولكن من أجل أي عدد منته $t \in \mathbb{R}$ لدينا:

$$\lim_{n \rightarrow \infty} \left| \sum_{k=1}^n \frac{\mu_k^{(3)}(\mathbf{i} t)^3}{6C_n^3} \right| \leq \lim_{n \rightarrow \infty} \sum_{k=1}^n \frac{\beta_k^{(3)} |t|^3}{6C_n^3} = \lim_{n \rightarrow \infty} \frac{B_n^3 |t|^3}{6C_n^3} = 0 \quad (4)$$

وباستخدام العلاقة (1) نحصل على العلاقة الآتية:

$$\lim_{n \rightarrow \infty} \sum_{k=1}^n \theta \left(\frac{\mu_k^{(3)} t^3}{6C_n^3} \right) \leq \lim_{n \rightarrow \infty} \sum_{k=1}^n \left[\frac{\mu_k^{(3)} t^3}{6C_n^3} \cdot \frac{6C_n^3}{\alpha_k t^3} \cdot \theta \left(\frac{\mu_k^{(3)} t^3}{6C_n^3} \right) \right] = 0$$

ومن هذه العلاقة الأخيرة ومراعاة العلاقتين العلاقة (3) و (4) ينتج من أجل أي عدد منته $t \in \mathbb{R}$ أن العلاقة الآتية صحيحة:

$$\lim_{n \rightarrow \infty} \sum_{k=1}^n u_{k,n} = -\frac{t^2}{2} \quad (5)$$

والآن من أجل حساب نهاية المجموع الآتي:

$$\sum_{k=1}^n u_{k,n}^2 = \sum_{k=1}^n \left[-\frac{\sigma_k^3 t^2}{2C_n^2} + \frac{\mu_k^{(3)}(\mathbf{i} t)^3}{6C_n^3} + \theta \left(\frac{\mu_k^{(3)} t^3}{C_n^3} \right) \right]^2$$

لدينا من متباينة ليابانوف ومراعاة العلاقة [22-8] ما يلي محققاً:

$$\begin{aligned} \lim_{n \rightarrow \infty} \sum_{k=1}^n \frac{\sigma_k^4 t^4}{4C_n^4} &\leq \lim_{n \rightarrow \infty} \sum_{k=1}^n \frac{\sqrt[3]{(\beta_k^{(3)})^4}}{4C_n^4} \cdot t^4 = \lim_{n \rightarrow \infty} \sum_{k=1}^n \frac{\beta_k^{(3)} \sqrt[3]{\beta_k^{(3)}}}{4C_n^3 C_n} \cdot t^4 \\ &\leq \lim_{n \rightarrow \infty} \sum_{k=1}^n \frac{\beta_k^{(3)}}{4C_n^3} \cdot t^4 = \lim_{n \rightarrow \infty} \sum_{k=1}^n \frac{B_n^3}{4C_n^3} \cdot t^4 = 0 \end{aligned}$$

وكذلك:

$$\lim_{n \rightarrow \infty} \left| \sum_{k=1}^n \left[\frac{\mu_k^{(3)} t^3}{6C_n^3} \right]^2 \right| \leq \lim_{n \rightarrow \infty} \sum_{k=1}^n \left| \frac{\mu_k^{(3)} t^3}{6C_n^3} \right|^2 \leq \lim_{n \rightarrow \infty} \sum_{k=1}^n \frac{(\beta_k^{(3)})^2 t^6}{36 C_n^6} \leq \lim_{n \rightarrow \infty} \sum_{k=1}^n \frac{B_n^6 t^6}{36 C_n^6} = 0$$

وبعد الأخذ بالحسبان العلاقة (1) نجد:

$$\lim_{n \rightarrow \infty} \sum_{k=1}^n \left(\theta \left(\frac{\mu_k^{(3)} t^3}{6C_n^3} \right) \right)^3 = 0$$

وكذلك سنحصل على العلاقات الثلاث الآتية:

$$\lim_{n \rightarrow \infty} \left| \sum_{k=1}^{n-1} \sum_{j=k+1}^n \frac{t^2 \mu_k^{(3)}}{C_n^2} \theta \left(\frac{\mu_j^{(3)} t^3}{C_n^3} \right) \right| = 0 \quad \& \quad \lim_{n \rightarrow \infty} \left| \sum_{k=1}^{n-1} \sum_{j=k+1}^n \frac{(\mu_k^{(3)})^2 \mu_j^{(3)} \mathbf{i}^3 t^5}{6 C_n^5} \right| = 0$$

$$\lim_{n \rightarrow \infty} \left| \sum_{k=1}^{n-1} \sum_{j=k+1}^n \frac{\mu_k^{(3)} \mathbf{i}^3 t^5}{3 C_n^3} \theta \left(\frac{\mu_j^{(3)} t^3}{C_n^3} \right) \right| = 0$$

وبما أنَّ $|u_{k,n}| > \frac{1}{2}$ ، وبعد الأخذ بالحسبان العلاقات الست الأخيرة فإنه سينتج لدينا الآتي:

$$\lim_{n \rightarrow \infty} \sum_{k=1}^n U_{k,n} u_k^2 = 0 \quad ; \forall k \in \mathbb{N}$$

ومن هذه العلاقة الأخيرة وبعد الأخذ بالحسبان العلاقة (2) ومراعاة العلاقة (5) فإنه سينتج لدينا أنه من أجل كل $t \in \mathbb{R}$ ما يلي مُحَقَّقًا:

$$\lim_{n \rightarrow \infty} \log \varphi_{Z_n}(t) = -\frac{t^2}{2}$$

ومن ثمَّ لأجل كل $t \in \mathbb{R}$ يصبح لدينا :

$$\lim_{n \rightarrow \infty} \varphi_{Z_n}(t) = e^{-\frac{t^2}{2}}$$

ومن هذه العلاقة الأخيرة ومن مبرهنة ليفي ينتج أنه من أجل كل $z \in \mathbb{R}$ ما يلي مُحَقَّقًا:

$$\lim_{n \rightarrow \infty} F_{Z_n}(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{t^2}{2}} dt$$

وبهذا يتمُّ البرهان.

لقد لاحظنا أنَّ نظرية ليابانوف تعطي شرطاً كافياً فقط لتحقيق العلاقة [8-22]، ولذلك سنقدم فيما يلي نظرية (ستقبلها دون برهان) تعطينا شرطاً لازماً وكافياً لتحقيق العلاقة [8-22]، وهذه النظرية تُعرف باسم مسألة ليندبرغ-فيلر.

(٨, ٣, ٤) مسألة ليندبرغ-فيلر **Lindenberg – Feller Problem**

إنَّ هذه المسألة تنطلق من على مستوى جيد من العمومية مقارنة بنظريات النهاية المركزية السابقة، إذ إنها تنطلق من أسرة متغيرات عشوائية مستقلة، وليس بالضرورة أن تكون متطابقة في التوزيع، وتبين أنه تحت شروط مُحَدَّدة يمكن الوصول إلى تقريب للتوزيع الطبيعي، وهذا هو محتوى النظرية الآتية.

(٨, ٣, ٤, ١) نظرية ليندبرغ-فيلر **Lindenberg – Feller Theorem**

لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ مستقلة وتملك عزوماً ابتدائية من المرتبة الثانية، ولنضع من أجل كل $n \in \mathbb{N}$ ما يلي:

$$C_n := \sqrt{\sum_{k=1}^n \sigma_k^2} \quad \& \quad Z_n := C_n^{-1} \cdot \sum_{k=1}^n (X_k - \mu_k)$$

عندئذ الشرط اللازم والكافي لتحقيق العلاقتين الآتيتين:

$$\text{a) } \lim_{n \rightarrow \infty} \max_{1 \leq k \leq n} \frac{\sigma_k}{C_n} = 0 \quad \& \quad \text{b) } \lim_{n \rightarrow \infty} F_{Z_n}(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{t^2}{2}} dt$$

هو أن يكون من أجل كل $0 < \varepsilon$ لدينا العلاقة الآتية مُحَقَّقَةً:

$$\lim_{n \rightarrow \infty} \frac{1}{C_n^2} \sum_{k=1}^n \int_{|x - \mu_k| > \varepsilon \cdot C_n} (x - \mu_k)^2 dF_{X_k}(x) = 0 \quad [8,23-a]$$

(٨, ٣, ٤, ٢) ملاحظة

إذا كان للمتغيرات العشوائية X_n دوال كثافة احتمالية f_{X_n} من أجل كل $n \in \mathbb{N}$ ، فعندئذ تكتب العلاقة [8-23-a] على

النحو الآتي أيضاً:

$$\lim_{n \rightarrow \infty} \frac{1}{C_n^2} \sum_{k=1}^n \int_{|x-\mu_k| > \varepsilon \cdot C_n} (x - \mu_k)^2 f_{X_k}(x) (dx) = 0 \quad [8,23-b]$$

وأما إذا كانت المتغيرات العشوائية X_n متقطعة من أجل كل $n \in \mathbb{N}$ ، وكتلها الاحتمالية $p_{n,\ell}$ عند النقاط $x_{n,\ell}$ من أجل كل $\ell \in \mathbb{N}$ ، فعندئذ تكتب العلاقة [8-23-a] على النحو الآتي:

$$\lim_{n \rightarrow \infty} \frac{1}{C_n^2} \sum_{k=1}^n \sum_{|x_{k,\ell} - \mu_k| > \varepsilon \cdot C_n} (x_{k,\ell} - \mu_k)^2 p_{k,\ell} = 0 \quad [8,23-c]$$

من نظرية ليندنبرغ-فيلر السابقة تنتج لدينا المقولة الآتية التي سنوردها دون إثبات أيضاً.

(٨, ٣, ٤, ٣) نتيجة

لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية مستقلة وعناصرها تملك عزوماً ابتدائية من المرتبة الثانية مع $\text{var } X_n > 0$ من أجل كل $n \in \mathbb{N}$ ، ولنضع بالتعريف ما يلي:

$$C_n = \sqrt{\sum_{k=1}^n \sigma_k^2} \quad \& \quad Z_n = C_n^{-1} \cdot \sum_{k=1}^n (X_k - \mu_k)$$

فإذا وجد ثابت $0 < c$ بحيث يكون من أجل كل $n \in \mathbb{N}$ لدينا $P(|X_n| \leq c) = 1$ ، فعندئذ تحقق العلاقة $\lim_{n \rightarrow \infty} C_n^2 = +\infty$ هو شرط لازم وكاف لكي تكون العلاقة الآتية مُحَقَّقة:

$$\lim_{n \rightarrow \infty} F_{Z_n}(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{t^2}{2}} dt$$

حيث نلاحظ هنا أن مُحَقَّق العلاقة $\lim_{n \rightarrow \infty} C_n^2 = +\infty$ يكافئ مُحَقَّق العلاقة $\sum_{k=1}^{\infty} \sigma_k^2 = +\infty$.

(٨, ٣, ٤, ٤) أمثلة

١- لنأخذ $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية برنولية مستقلة فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ بحيث إنه من أجل كل $n \in \mathbb{N}$ X_n معلمة p_n ، فعندئذ سيكون من أجل كل $k \in \mathbb{N}$ لدينا القيم الآتية:

$$\mu_k = \mathbf{E} X_k = p_k \quad \& \quad \sigma_k^2 = \text{var } X_k = p_k \cdot (1 - p_k) \quad \& \quad C_n^2 = \sum_{k=1}^n \sigma_k^2 = \sum_{k=1}^n p_k \cdot (1 - p_k)$$

وهنا نجد أن تباعد المتسلسلة العددية $\sum_{k=1}^{\infty} p_k \cdot (1 - p_k)$ هو شرط لازم وكاف حتى يكون توزيع المتغير العشوائي Z_n مقارباً للتوزيع الطبيعي بمتوسط $\sum_{k=1}^n p_k$ وتباين $\sum_{k=1}^n p_k \cdot (1 - p_k)$ ، أي إنه يكون $Z_n \sim N\left(\sum_{k=1}^n p_k, \sqrt{\sum_{k=1}^n p_k \cdot (1 - p_k)}\right)$ إذا وفقط إذا كانت المتسلسلة العددية $\sum_{k=1}^{\infty} p_k \cdot (1 - p_k)$ متباعدة نحو ∞ ، وتجدر الإشارة هنا إلى أنه يُقال في هذه الحالة عن المتغير العشوائي Z_n إنه خاضع للتوزيع ثنائي النقطة المتعدد أو الحداني المعمم.

٢- يوجد في مستودع أنواع مختلفة من المصابيح معبأة في صناديق بحيث يحوي كل صندوق عدداً منتهياً من المصابيح. إنَّ حظنا في الحصول على مصباح معيب في شحنة ليس نفسه في كل الشحنات التي تعود إلى أنواع مختلفة. الآن سنفترض أن كل صندوق يحوي

عدداً كبيراً جداً من المصابيح (ومن ثم إزالة بعض المصابيح منها لا يؤثر في ترتيبها ووضعها ضمن الصندوق)، وأنه لدى إنتاج الصندوق ذي الرقم k يكون p_k هو احتمال الحصول على مصباح سليم (احتمال النجاح) من هذا الصندوق، وأنه لدينا:

$$p_1 = 0.95 \text{ \& } p_2 = 0.90 \text{ \& } p_3 = 0.98 \text{ \& } p_4 = 0.92 \text{ \& } p_5 = 0.96$$

قمنا بسحب عشوائي لعشرين مصباحاً من كل صندوق، ومن ثم اختبار هذه المصابيح فوجد منها 11 مصباحاً معيباً (لا تحقق المواصفات المطلوبة)، وهذه النتيجة أثارت في نفسنا الشك تجاه افتراضنا للقيم p_k (فقد تكون تلك القيم مبالغ فيها)، ولكي نبين إن كان شكنا مبرراً أم لا سنقوم بدراسة هذه القضية على النحو الآتي. إن النموذج الرياضي لهذه المسألة يبدو لنا كما يلي:

لدينا 100 متغير عشوائي مستقل X_1, X_2, \dots, X_{100} برنولية، ولكنها ليست جميعها متطابقة في التوزيع. إن هذه المتغيرات العشوائية موزعة في خمس فئات متساوية الحجم بحيث إن الفئة ذات الرقم k تنتمي إليها تلك المتغيرات العشوائية ذات الاحتمالات p_k من أجل أي $k \in N_5$ ، ولنشكل المجموع الآتي:

$$S_{100} = X_1 + \dots + X_{20} + X_{21} + \dots + X_{40} + X_{41} + \dots + X_{100}$$

فعندئذ يكون لـ S_{100} توزيع حداني معمم بالقيم المميزة الآتية:

$$ES_{100} = (20)(0.95) + (20)(0.90) + (20)(0.98) + (20)(0.92) + (20)(0.96) = 94.20$$

$$\begin{aligned} \text{var } S_{100} &= (20)(0.05)(0.95) + (20)(0.10)(0.90) + (20)(0.02)(0.98) \\ &\quad + (20)(0.02)(0.92) + (20)(0.04)(0.96) = 5.382 \end{aligned}$$

ومن ثم ينتج لدينا أن $\sigma = \sqrt{\text{var } S_{100}} = 2.32$ ، ولننظر الآن إن كانت المتسلسلة $\sum_{k=1}^{\infty} p_k \cdot (1-p_k)$ متباعدة أم لا؟

من أجل ذلك سنفترض جدلاً أن هذه المتسلسلة العددية متقاربة، فعندئذ يجب أن يسعى حدّها العام إلى الصفر عندما n يسعى إلى اللانهاية (وذلك بحسب الشرط اللازم لتقارب المتسلسلات العددية)، وهكذا ينتج لدينا أن $\min\{p_n, 1-p_n\} \xrightarrow{n \rightarrow \infty} 0$ ، وبناءً على ذلك فإن المتتالية العددية $(p_n)_{n \in \mathbb{N}}$ إما أن تحوي متتالية جزئية متقاربة من الصفر أو أن تحوي متتالية جزئية متقاربة من الواحد، وتفسير ذلك من أجل هذا المثال هو أن المتسلسلة $\sum_{k=1}^{\infty} p_k \cdot (1-p_k)$ تكون متقاربة إذا كانت معظم شحنات المصابيح التي قمنا باستلامها إما شحنة مصابيح سليمة تماماً أو معيبة تماماً، ولكن من خبرات السنوات الطويلة في إنتاج المصابيح ومن عدد المصابيح المعيبة التي نحصل عليها في اختبارات الجودة اتضح لنا أنه لا يمكن أن تحدث لدينا مثل هذه الحالة. إذن فرضنا الجدلي من أن المتسلسلة $\sum_{k=1}^{\infty} p_k \cdot (1-p_k)$ متقاربة غير صحيح، ومن أجل إزالة هذا التناقض يجب أن تكون هذه المتسلسلة متباعدة.

الآن، وبحسب التطبيق الأخير يكون لدينا $S_{100} \sim N(94.2, 2.32)$ ، أي إن للمتغير العشوائي S_{100} توزيعاً طبيعياً $N(94.2, 2.32)$ على وجه التقريب، ومن ثم يمكننا أن نكتب الآتي:

$$P(S_{100} \leq 89) = P\left(\frac{S_{100} - 94.2}{2.32} \leq -2.25\right) = P(Z \leq -2.25) \approx \Phi(-2.25) = 0.0122$$

علمنا أننا قد قمنا باستيعار المتغير العشوائي S_{100} من خلال وضع $Z := \frac{S_{100} - 94.2}{2.32}$ ، فيكون لدينا $Z \sim N(0, 1)$. إن

قيمة الاحتمال الأخيرة تُعدّ صغيرة نسبياً، وتعني بدورها أن قيم p_k المعطاة سابقاً أمر مبالغ فيه وينطوي على تفاؤل زائد.

(٨, ٣, ٥) مسألة غنيدينكو Gnedenko Problem

قمنا فيما سبق بدراسة تقارب متتاليات دوال التوزيع لمجاميع متغيرات عشوائية مُستعيرة (تم استيعارها) من دالة التوزيع الطبيعي، ولكن في الحالة العامة ليس بالضرورة أن تتقارب متتاليات دوال التوزيع لتلك المتغيرات العشوائية من التوزيع الطبيعي. هنا سوف لن نبحث في الإجابة العامة على هذه المسألة، ولكن سنقدم دراسة لحالة خاصة عندما يكون لدينا متتالية متغيرات عشوائية متقطعة ومستقلة فقط. إن هذه الحالة الخاصة لدراسة التقارب تُدعى **نظرية النهاية المركزية الموضعية** Local Central Limit Theorem، وهذا يعني دراسة تقارب متتالية دوال التوزيع الاحتمالية من دالة توزيع احتمالية ما يمكن تعيينها، وفي هذا المجال تكون أكثر الدراسات مركزة على المتغيرات العشوائية المتقطعة المستقلة والمتطابقة التوزيع التي قيمها دوال خطية لأعداد صحيحة من الشكل $h \cdot k + a$ علماً أن $a, h \in \mathbb{R}$ مع $0 < h$ و $k \in \mathbb{Z}$. إن أمثال هذه التوزيعات تُدعى **توزيعات شبكية** Nets Distribution، والعدد h يُدعى **عرض خطوة التوزيع**. إن العدد h (وكما هو واضح) ليس إلا الفرق لقيمتين من قيم المتغير العشوائي X_k ، وإذا كان h هو أكبر قاسم مشترك لتلك الفروق فعندئذ h يُدعى **عرض الخطوة الأعظمي**.

نقدم فيما يلي إحدى نظريات النهاية المركزية التي ينطبق عليها التمهيد السابق. إن هذه النظرية تُعرف باسم **نظرية غنيدينكو** (وستقبلها دون برهان) تعود إلى الرياضياتي الروسي **غنيدينكو** (1912-1995) Boris Vladimirovich Gnedenko الذي تتلمذ على يد الرياضياتي الروسي كلموغوراف.

(٨, ٣, ٥, ١) نظرية غنيدينكو Gnedenko Theorem

لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية متقطعة فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، فإذا كانت هذه المتغيرات العشوائية تملك عزوماً ابتدائية من المرتبة الثانية، ومستقلة، ومتطابقة في التوزيع، وتأخذ قيماً صحيحةً باحتمال موجب تماماً، فعندئذ من أجل كل x من \mathbb{R} تكون العلاقة الآتية مُحَقَّقة **إذا وفقط إذا** كان عرض الخطوة الأعظمي لتوزيعات المتغيرات العشوائية X_n يساوي الواحد من أجل كل $n \in \mathbb{N}$:

$$\lim_{n \rightarrow \infty} \left[\sigma \sqrt{n} \alpha_n(x) - \frac{1}{\sqrt{2\pi}} e^{-\frac{x_{n,x}^2}{2}} \right] = 0 \quad [8,24]$$

علماً أنه من أجل كل $n \in \mathbb{N}$ و x من \mathbb{R} لدينا:

$$\alpha_n(x) := P\left(\sum_{i=1}^n X_i = x\right) \quad \& \quad x_{n,x} := \frac{x - n \cdot \mu}{\sigma \sqrt{n}}$$

$$\mu = E X_n \quad \& \quad \sigma = +\sqrt{\text{var } X_n} > 0$$

(٨, ٣, ٥, ٢) ملاحظات

- ١- إذا كان عرض الخطوة الأعظمي يساوي الواحد فعندئذ يُقال عن المتغير العشوائي إنه يُحَقِّق الشرط [w].
- ٢- يلاحظ أن نظرية النهاية المركزية الموضعية لـ **موافير-لابلاس** هي حالة خاصة من النظرية السابقة، وذلك عندما يكون:

$$P(X_n = 1) = p \quad \& \quad P(X_n = 0) = 1 - p \quad ; \forall n \in \mathbb{N}$$

نقدم فيما يلي مبرهنة تعطينا إحدى النتائج المتعلقة بتحقيق الشرط [8-24].

(٨, ٣, ٥, ٣) مبرهنة

ليكن X متغيراً عشوائياً فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، ويأخذ قيماً صحيحة فقط، ويُحَقِّق الشرط [w]، فعندئذ تُحَقِّق الدالة

المميزة لهذا المتغير العشوائي البندين الآتيتين:

$$١- \text{ لدينا } \varphi_X(2\pi) = 1.$$

$$٢- \text{ من أجل } 0 < |t| < 2\pi \text{ لدينا } |\varphi_X(t)| < 1$$

البرهان: من أجل برهان البند:

١- سنفترض أن $p_k = P(X = k)$ لكل k من \mathbb{Z} ، فعندئذ من أجل كل $t \in \mathbb{R}$ سيكون لـ $\varphi_X(t)$ العرض الآتي:

$$\varphi_X(t) = \sum_{k=-\infty}^{\infty} p_k \cdot e^{ik}$$

ومن ثم ينتج لدينا من أجل $t = 2\pi$ ما يلي:

$$\varphi_X(2\pi) = \sum_{k=-\infty}^{\infty} p_k e^{2\pi i k} = \sum_{k=-\infty}^{\infty} p_k = 1$$

وبذلك يتم إثبات الطلب الأول.

٢- سنفترض جدلاً أنه من أجل قيمة t_o مع $0 < |t_o| < 2\pi$ لدينا العلاقة $|\varphi_X(t_o)| = 1$ مُحَقَّقة، فعندئذ يوجد عدد $a \in \mathbb{R}$

بحيث يكون $\varphi_X(t_o) = e^{ia}$ ، ومن ثم يمكننا أن نكتب العلاقة الآتية:

$$\int_{-\infty}^{+\infty} e^{it_o x} dF_X(x) = e^{ia}$$

وبضرب طرفي العلاقة الأخيرة بـ e^{-ia} ينتج لدينا ما يلي:

$$\int_{-\infty}^{+\infty} e^{i(t_o x - a)} dF_X(x) = 1$$

ومن معطيات الفرض (X متقطع بقيم صحيحة) يمكننا أن نكتب:

$$\int_{-\infty}^{+\infty} \cos(t_o x - a) dF_X(x) = \sum_{k=-\infty}^{+\infty} p_k \cos(t_o x - a) = 1$$

وتكون هذه العلاقة الأخيرة مُحَقَّقة فقط عندما يكون من أجل أية قيمة $k \in \mathbb{Z}$ لدينا العلاقة $\cos(t_o x - a) = 1$ مُحَقَّقة، ومنه ينتج لدينا، أنه من أجل كل $k \in \mathbb{Z}$ يكون لـ X القيم الآتية:

$$x_k = \frac{a}{t_o} + b_k \frac{2\pi}{t_o} \quad ; \quad b_k \in \mathbb{Z}$$

ولكن لدينا بالفرض x_k هي قيم صحيحة، ولذلك سيكون للفرق بين أزواج القيم x_k الشكل $s \cdot h$ علماً أن s هو عدد صحيح ما، وأما $h = \frac{2\pi}{|t_o|}$ فهو أكبر قاسم مشترك لفروقات القيم x_k ، وبسبب أن $|t_o| > 2\pi$ ينتج لدينا أن $h < 1$ وهذا يناقض الشرط $[w]$ ، ولإزالة هذا التناقض يجب أن يكون من أجل $0 < |t| < 2\pi$ لدينا $|\varphi(t)| < 1$ ، وبهذا يتم المطلوب.

(٤، ٥، ٣، ٨) تطبيق

لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية متقطعة فوق فضاء احتمالي $[\Omega, \mathcal{A}, P]$ ، وتملك عزوماً ابتدائية من المرتبة الثانية، مستقلة، متطابقة في التوزيع وتأخذ قيماً صحيحة لها الشكل الآتي:

$$x_{n,k} = a + h \cdot k \quad ; \forall k \in \mathbb{Z}$$

مع $0 < h$ هو القاسم المشترك الأكبر لفروقات القيم بين الأزواج $x_{n,k}$. الآن لو أخذنا:

$$Z_n = \frac{X_n - a}{h} \quad ; \forall n \in \mathbb{N}$$

فعندئذ المتغيرات العشوائية X_n تأخذ قيماً صحيحة من أجل كل $n \in \mathbb{N}$ ، وكذلك تُحقّق الشرط $[w]$ أيضاً، وهكذا يمكن تطبيق نظرية النهاية المركزية الموضعية لـ [غندينكو](#) على المتتالية $(X_n)_{n \in \mathbb{N}}$ وتكون العلاقة [8–24] مُحَقَّقة من أجلها.

هذا ما تيسّر تقديمه من أجل الجزء النظري والتطبيقي لهذا الفصل

تمارين الفصل الثامن

١- تقدّم 1000 شخص إلى اختبار مقابلة من أجل العمل بوظائف إدارية، فإذا علمت أنّ احتمال رسوب أي شخص في هذا الاختبار يساوي 0.10، وأنّ الاختبارات هؤلاء الأشخاص تتم بشكل مستقل لكل منهم عن الآخر، فعندئذ:

أ- ما هو احتمال رسوب 50 شخصاً على الأقل؟

ب- ما هو احتمال أن يكون عدد الأشخاص الذين سيرسبون في هذا الاختبار ما بين 50 و 100 شخص؟

٢- تقوم طائرة مدنية برحلات ما بين المدن أو الدول، وبشكل مستقل كل منها عن الأخرى، فإذا كان X_n يصف حالة السلامة لوصول الطائرة في الرحلة رقم n ، وكان من أجل كل $n \in \mathbb{N}^0$ لدينا العلاقة الآتية مُحَقَّقة:

$$P(X_n = 1) = \frac{1}{2^n}$$

علماً أنّ X_0 يمثّل حالة الطائرة قبل الإقلاع الأول (أي إنّها كانت سليمة باحتمال يساوي الواحد)، وأنّ الـ 1 يعني الوصول إلى هدفها دون مخاطر تُذكر، ولنأخذ:

$$S_n = X_1 + X_2 + \dots + X_n \quad ; n \in \mathbb{N}^0$$

فعندئذ هل ستتقارب المتتالية $\left(\frac{S_n}{n}\right)_{n \in \mathbb{N}}$ بالتوزيع، وإلى أين ستتقارب؟

٣- في استطلاع للرأي حول خدمة البلدية في مدينة ما شمل 10000 شخص وبشكل مستقل كل منهم عن الآخر، وبحيث تكون الإجابة (راض أو غير راض)، فإذا افترضنا أنّ أي الإجابتين لها الاحتمال نفسه، فما هو احتمال أن يكون عدد من الأشخاص الذين أجابوا بعبارة "راض" ما بين 4985 و 5005؟

٤- لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية مستقلة ومتطابقة التوزيع مع توزيع متغير عشوائي X خاضع للتوزيع الهندسي بمعلّمة $p = 0.25$ ، ولنأخذ $S_n = \sum_{i=1}^n X_i$ من أجل كل $n \in \mathbb{N}$ ، والمطلوب حساب الاحتمال $P(70 < S_{300} < 130)$.

٥- نقوم برمي حجر نرد متوازن لعدد كبير جداً من المرات، وليكن X_n متغيراً عشوائياً راصداً لنتيجة الرمية ذات الرقم n مع $n \in \mathbb{N}$ ، والمطلوب حساب الاحتمالين الآتيين:

$$P(\bar{X}_{1000} < 3) = ? \quad \& \quad P(\bar{X}_{1000} > 5) = ?$$

ماذا تلاحظ، وما السبب في ذلك، علماً أنّ $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$.

٦- تقوم دائرة إلكترونية بتوليد عشوائي لأعداد حقيقية $0 \leq x \leq 1$ وبشكل مستقل كل منها عن الآخر، فإذا علمت أنّ التوزيع المنتظم المستمر على الفترة $[0, 1]$ هو المعتمد في عشوائية القيم المولدة، فعندئذ:

أ- إذا ولدت هذه الدائرة 100 رقماً عشوائياً فما هو احتمال أن يكون متوسط هذه القيم قيمة أكبر من 0.505، وكذلك ما هو احتمال أن يكون متوسط هذه القيم قيمة أصغر من 0.495؟

ب- إذا ولدت الدائرة 1000 رقم عشوائي فما هو احتمال أن يكون متوسط هذه القيم قيمة أكبر من 0.505، وكذلك ما هو احتمال أن يكون متوسط هذه القيم قيمة أصغر من 0.495، وماذا تلاحظ؟

٧- لدينا سبع جامعات لكل منها نظام ومنهج خاص في التعليم، وفي كل جامعة عدد ما من الطلاب المتعثرين، فإذا كان p_k هو احتمال الحصول على طالب متعثر من الجامعة رقم k ، فعندئذ بفرض أن:

$$p_1 = 0.95 \quad \& \quad p_2 = 0.93 \quad \& \quad p_3 = 0.98$$

$$p_4 = 0.99 \quad \& \quad p_5 = 0.92 \quad \& \quad p_6 = 0.96 \quad \& \quad p_7 = 0.98$$

وقمنا بسحب عشوائي لخمسين طالباً من كل جامعة، ومن ثمّ الكشف عن وضع جميع الطلاب الذين تمّ اختيارهم فوجدنا من بينهم 50 طالباً متعثراً، فهل تثير لديك هذه النتيجة الشك تجاه القيم p_k المقدمة آنفاً، ولماذا؟

٨- لتكن $(X_n)_{n \in \mathbb{N}}$ متتالية متغيرات عشوائية مستقلة ومتطابقة في التوزيع مع متغير عشوائي X خاضع لتوزيع كوشي المعياري، والمطلوب تعيين توزيع المتوسط \bar{X}_n (استفد من نتيجة التمرين ١٦ / من تمارين الفصل السابع).

٩- نقوم بإجراء تجارب عشوائية مستقلة ونرصد من خلالها تحقق حدث ما A ، فعندئذ كم مرة يجب أن نكرر هذه التجارب حتى يكون للفرق بين احتمال الحادث A وتكراره النسبي أقل من 0.01 باحتمال قدره 0.99 على الأقل؟

١٠- لدينا مصنع ينتج دارات متكاملة من نوع معين بحيث إن نسبة الدارات المعطلة في إنتاجه تساوي 0.1%، قمنا بشراء 10000 دارة من إنتاج هذا المصنع، فما هو احتمال أن يكون عدد الدارات المعطلة لدينا يقع ما بين 400 و600 دارة؟

١١- يوجد في مستودع لصناعة الأواني الخزفية أنواع مختلفة من صحنون الطعام معبأة في صناديق بحيث يحوي كل صندوق عدداً كبيراً جداً من الصحنون (ولكن منته). نأخذ عشوائياً أربعة صناديق B_1 ، B_2 ، B_3 و B_4 من مجمل الإنتاج الموجود في المستودع، ومن ثمّ نقوم بسحب عشوائي لخمسة وعشرين صحناً من كل صندوق، وبعد ذلك نتفحص هذه الصحنون فوجدنا منها 10 صحنون معيبة، فإذا علمنا أن احتمال الحصول على صحن معيب (لا يحقق المواصفات المطلوبة) من هذه الصناديق الأربعة هو:

$$p_1 = 0.05 \quad \& \quad p_2 = 0.02 \quad \& \quad p_3 = 0.15 \quad \& \quad p_4 = 0.10$$

على الترتيب، وأنه من خبرتنا السابقة في هذا المجال من غير الممكن أن يكون كامل المنتج سليماً أو كله معيباً، فهل تثير هذه النتيجة في نفسك الشك تجاه افتراضنا للقيم p_k المعطاة (علّل ذلك)؟

الفصل التاسع

مدخل إلى نظرية المعاينة

AN INTRODUCTION TO SAMPLING THEORY

(٩, ١) مفاهيم ومصطلحات أساسية

Basic concepts and expressions

سنذكر أولاً ببعض المفاهيم التي تخص هذا الموضوع وقدّمت في الفصل الأول من هذا الكتاب. لقد عرضنا في ذلك الفصل تمهيداً مبسطاً حول علم الإحصاء وأهميته في مختلف العلوم، ومن ثمّ تطرقنا إلى مفهوم المجتمع الإحصائي وحجمه، حيث ذكرنا أنّ المجتمع الإحصائي هو أي تجمع لأشياء تجمع بينها صفة مشتركة واحدة على الأقل لتكون محل دراسة لهدف معين، ومكونات هذا المجتمع تدعى أفراداً أو عناصر، وأما عدد العناصر المكونة للمجتمع الإحصائي فإنها تدعى حجم المجتمع، وفي حال كان حجم المجتمع منتهياً يرمز لحجمه بحرف لاتيني كبير من قبيل N أو M أو بعد ذلك أوضحنا ضرورة التعامل مع العينة للحصول على البيانات التي نود استخدامها في دراسة إحصائية ما، وذكرنا أنّ العينة هي جزء يسحب من المجتمع الإحصائي لتنفيذ الدراسة الإحصائية المطلوبة متجنّبين بذلك استخدام جميع عناصر المجتمع (المسح الشامل) لأسباب معينة تفرضها طبيعة الدراسة بحيث إما أن نكون غير قادرين على التعامل مع كل عناصر المجتمع، أو أنّ ذلك يجعل الدراسة عقيمة وغير ذات معنى، أو أنّ التعامل مع كل عناصر المجتمع مكلف مادياً أو زمنياً (أو هنا لا يفيد الحصر). كذلك ذكرنا أنّ العلم الذي يبحث في كيفية أخذ العينات يعرف باسم **نظرية المعاينة**، وأوضحنا أنّ هذه النظرية تُعدّ جزءاً لا يتجزأ من العلوم الإحصائية المختلفة، وأنّ تطبيقاتها في البحوث العلمية تمكننا من الحصول على نتائج سريعة وبكلفة زهيدة نسبياً إذا ما قورنت بكلفة المسح الشامل، وأكثر من ذلك ينظر في كثير من الحالات إلى هذه النظرية على أنّها الوسيلة الوحيدة المتاحة في البحث العلمي.

الآن، وبعد هذه المقدمة الموجزة سنقوم باستكمال بعض المصطلحات والمفاهيم المستخدمة في إطار نظرية المعاينة، ولكن بشكل موجز تقريباً حيث يمكن لمن يود الاطلاع على المزيد الرجوع إلى المراجع ذات الصلة التي ومنها [17] و [18] و [24] و [33] و [40] و [45] و [64] في فهرس مراجع هذا الكتاب.

(٩, ١, ١) تعريف (الإطار Framework)

الإطار هو مجموعة كل الرموز أو الأرقام أو الأحرف التي تُمثّل عناصر المجتمع الإحصائي عند إعداده من أجل سحب عينة لإخضاعها للدراسة.

(٩, ١, ٢) تعريف (وحدة المعاينة Sampling Unit)

وحدة المعاينة هي مصطلح يُطلق على مجموعة العناصر من المجتمع الإحصائي التي تتميز عن العناصر الأخرى بصفة معينة.

في الواقع هذه الصفة التي تميز العناصر تُشكّل البنية الأساسية لعملية أخذ جزء أو أكثر من المجتمع الذي هو قيد الدرس، كأن نأخذ على سبيل المثال من مجتمع الطلبة في بلد ما جزءاً من الطلبة ذوي **التقدير الممتاز** من أجل معرفة متوسط الدرجة لمحققي هذا التقدير، و من ثمَّ وحدة المعاينة هنا تتمثل بالطلبة ذوي التقدير الممتاز، وهكذا نلاحظ أنَّ وحدة المعاينة التي تصلح لنوع معين من الدراسة قد لا تصلح لنوع آخر من الدراسات الأخرى المتعلقة بالمجتمع الإحصائي نفسه.

في الحقيقة إنَّ عملية سحب العينات تتطلب تمعناً وتفكيراً ملياً في آليتها، وذلك لأنَّ نتائج السحب يبنى عليها قرارات مصيرية بخصوص الدراسة الإحصائية، فكلما كانت طريقة السحب أكثر ملاءمة للدراسة الإحصائية أدى ذلك إلى نتائج أفضل.

(٩, ١, ٣) طرائق سحب العينة Methods of Sampling:

في الواقع يمكن إجراء عملية سحب العينة من المجتمع بإحدى طريقتين:

أ- السحب مع الإعادة (أو الإرجاع) Draw with Replacement:

في هذا النوع من السحب يُعاد العنصر المسحوب (من المجتمع) إلى المجتمع ثانية بعد تطبيق الدراسة الإحصائية عليه، ومن ثمَّ يمكن للعنصر أن يظهر عدداً كيفياً من المرات خلال عمليات السحب، فعلى سبيل المثال لو افترضنا أنَّ لدينا وعاء يحوي N كرة (المجتمع حجمه N) متماثلة ومرقمة من 1 وحتى N ، وقمنا بخلط هذه الكرات جيداً، ومن ثمَّ سحب كرة من الوعاء وتسجيل رقمها، ثمَّ نعيدها إلى الوعاء ثانية، ونخلط الكرات من جديد بشكل جيد، وبعد ذلك نسحب كرة ثانية ونسجل رقمها ثمَّ نعيدها إلى الوعاء من جديد، وهكذا... نكرّر هذه العملية لـ n مرة متتالية، فعندئذ نكون قد حصلنا على عينة حجمها n ، فعندئذ يُقال عن هذه العينة إنها ناتجة عن السحب مع الإعادة (أو الإرجاع، أو الإحلال). لاحظ هنا أنَّه يمكننا أن نختار عناصر هذه العينة من المجتمع بعدد من الطرائق يساوي $N \cdot N \cdot \dots \cdot N = N^n$ طريقة.

ب- السحب بدون إعادة (أو بدون إرجاع) Draw without Replacement:

في هذا النوع من السحب لا يُعاد العنصر المسحوب إلى المجتمع ثانية بعد تطبيق الدراسة الإحصائية عليه، وإنَّما يُحْد جانباً (إما لعدم الرغبة في استخدامه مرة ثانية أو بسبب تلفه نتيجة للبحث والدراسة)، ومن ثمَّ فإنَّه من غير الممكن ظهور العنصر أكثر من مرة واحدة خلال عمليات السحب، فعلى سبيل المثال لو افترضنا أنَّه لدينا وعاء يحوي N كبسولة عقار دوائي من إنتاج مصنع للدواء (ولتكن على سبيل المثال كبسولات سيتامول الخافض للحرارة)، وقمنا بخلط هذه الكبسولات جيداً، ومن ثمَّ نسحب إحداها ونخضعها للتحليل المخبري للتحقق من نسبة المادة الدوائية الفعالة فيها، فعندئذ نلاحظ أنَّه لا يمكننا إعادة هذه الكبسولة إلى الوعاء الحاوي للكبسولات؛ لأنَّها قد أتلفت، وبعد ذلك نخلط الكبسولات المتبقية من جديد بشكل جيد، ونقوم بسحب كبسولة ثانية وتنفيذ الدراسة الإحصائية عليها، وهكذا نستمر في تكرار هذه العملية لـ n مرة متتالية، فنكون بذلك قد حصلنا على عينة بحجم n ، وفي هذه الحالة يُقال عن العينة إنها ناتجة عن السحب بدون إعادة (أو إرجاع، أو إحلال).

نلاحظ هنا أنَّه لا يمكن للعنصر أن يظهر أكثر من مرة واحدة خلال عمليات السحب، ولهذا السبب فإنَّه لدى التعامل مع هذا النوع من السحب للعينات يجب النظر إلى حجم المجتمع والعينة بحيث لا يؤثر سحب العينة في حجم المجتمع، ومن ثمَّ يفترض أنَّ يكون حجم المجتمع كبيراً بقدر كافٍ إذ ما قورن بحجم العينة حيث ذكرنا سابقاً أنَّه في مثل هذه الحالات من المقبول إحصائياً أن يكون $20n \leq N$. كذلك يُلاحظ أنَّه يمكن اختيار عناصر هذه العينة من المجتمع الإحصائي بعدد من الطرائق يساوي:

$$N \cdot (N - 1) \cdot (N - 2) \cdot \dots \cdot (N - n + 1) = \frac{N!}{(N - n)!}$$

(٩,٢) تصنيف العينات**Classification of Samples**

مما تقدم يتبين لنا أن استخدام مفهوم العينة في الدراسة (أو البحث الجزئي) إنما هو وسيلة لتعميم ما تم التوصل إليه من نتائج على المجتمع بأكمله، على اعتقادنا أن هذه العينة المأخوذة من المجتمع هي تمثيل مقبول للمجتمع، وذلك وفقاً لمعايير نعدّها مقنعة لأجل العمل الذي نقوم به، وبحيث لا يؤدي ذلك إلى تناقضات علمية، وفي هذا الإطار تبرز الوسائط العامة ومهارة الباحث وحده في تعيين نوع العينة التي يجب التعامل معها، فإما أن تكون العينة نتيجة لاختيارات عناصر من المجتمع دون تدخل من قبل الباحث، ومن ثمّ يسيطر على هذا النوع من العينات طابع العشوائية في سحب العناصر من المجتمع، أو أن تكون نتيجة لاختيارات محدّدة من عناصر المجتمع بتدخل مباشر من قبل الباحث، وذلك اعتقاداً منه أن هذه العناصر المنتقاة هي تمثيل جيد للمجتمع المدروس، ومن ثمّ العينة الناتجة ستكون ذات طابع عمدي أو قصدي (ليست عشوائية).

إذاً، وبناءً على مذكّر يمكن تصنيف العينات التي ستسحب من المجتمع الإحصائي إلى نوعين:

الأول: عينات عشوائية Random Samples، وتكون عناصرها قد سُحبت بطرائق عشوائية.

الثاني: عينات عمدية (أو قصدية) Intentional Samples، وعناصرها تنتج عن عمليات انتقاء وفقاً للرأي الشخصي للباحث.

(٩,٢,١) العينات العشوائية Random Samples

فيما يلي سنقوم بعرض موجز لبعض نماذج العينات العشوائية. علماً أن العينة العشوائية هي عينة تسحب من المجتمع بطرائق عشوائية، وبما أن الطرائق العشوائية كثيرة فإنّه سيكون لدينا نماذج عديدة من العينات العشوائية. هذا من جانب، ومن جانب آخر، فإنّ العينات العشوائية على مختلف أنواعها تجعل الاستعانة بنظرية الاحتمالات أمراً ممكناً في تعميم النتائج من العينة على المجتمع، ومن ثمّ تقديم الاختبارات المتعلقة بفرضيات حول هذا المجتمع، وكذلك في حساب الأخطاء المرتكبة في هذا التعميم.

في الحقيقة توجد طرائق كثيرة لسحب العينات العشوائية، ومعظمها معروف ومألوف لدى الكثير من الناس مثل طريقة الكيس أو الصندوق، حيث يوضع بداخله أشياء (مثل قصاصات ورق دوّن عليها أرقاماً أو أسماء أو ...) تمثّل عناصر المجتمع، وبعضها الآخر خاص بالباحثين العلميين مثل طريقة جداول الأرقام العشوائية، وطريقة مونت كارلو، والمولدات الإلكترونية للأرقام العشوائية (مولّدات أرقام عشوائية وفقاً لتوزيع احتمالي ما) الموجودة في الحاسبات الإلكترونية، ولكننا سنعرض هنا طريقة استخدام جدول الأرقام العشوائية فقط (حيث يمكن لمن يود الاطلاع على المزيد الرجوع إلى كتب نظرية المعاينة).

في معظم كتب الإحصاء توجد جداول إحصائية متنوعة، منها جداول تحوي خانات ذات عدد متساو من الأرقام، فمنها مكوّنة من خانة واحدة تشتمل على الأرقام من 1 وحتى 9 (ومن الممكن أن يبدأ الترقيم من الـ 0 أيضاً)، أو مكوّنة خانتين تشتمل على الأرقام من 01 وحتى 99، أو مكوّنة من ثلاث خانات تشتمل على الأرقام من 001 وحتى 999، أو أكثر من ذلك، وتتوارد هذه الأرقام بشكل عشوائي (مولّدة باستخدام بعض التوزيعات الاحتمالية، وغالباً التوزيع المنتظم)، وتعرف هذه الجداول باسم **جداول الأرقام العشوائية** Table of Random Digits حيث تمّ نشر أول جدول للأرقام العشوائية من قبل الإحصائي الإنكليزي **لونارد هنري تيبس** Leonard Henry Tippet (1902-1985) وذلك في عام 1927. إنّ هذه الجداول على أنماط وأشكال مختلفة كما ذكرنا ذلك آنفاً، ومنها على سبيل المثال النماذج الآتية:

6 1 5 3	5 9 8 1	4 8 7 8	9 2 8 0
4 1 5 9	1 9 3 4	2 9 1 0	0 2 0 4
6 7 5 0	5 0 8 5	4 8 7 8	1 2 8 5
5 0 5 0	7 9 8 9	4 8 7 8	9 7 8 0

جزء من جدول أحادي الخانات

65 10 51 33	95 99 48 11	14 08 17 78
41 51 75 99	91 19 33 84	02 69 71 20
26 07 05 50	35 01 78 25	74 88 47 28
05 70 71 09	37 91 18 90	41 80 79 81
05 40 55 63	25 19 58 15	64 09 11 18
11 81 65 90	41 14 35 74	12 09 41 23
20 02 55 10	25 71 70 75	34 81 07 08
45 40 41 59	07 01 98 09	81 10 59 99

جزء من جدول ثنائي الخانات

67835	63314	50162	36738
25014	15460	11730	76548
05393	96770	56087	40875
13351	93994	22375	00953
85423	60698	01898	61414

جزء من جدول خماسي الخانات

0310650	1098218	5451034	3363111	9125545
9957519	1563948	1001101	0904014	7521708
3420217	7991198	1054641	5030981	0110075
7134299	9012191	1777759	3210333	8354474
2085202	6456419	7117771	2065550	0012190
1755559	8870333	8354621	1105393	4496770
1250145	7154606	1117300	7765488	9614141

جزء من جدول سباعي الخانات

من أجل استخدام جدول الأرقام العشوائية نقوم أولاً بترقيم عناصر المجتمع بأرقام متسلسلة بدءاً من الواحد وصاعداً، ثم نأخذ خانة من خانات هذا الجدول بطريقة عشوائية (كأن نغمض عينينا ونضع إصبعنا على الجدول، فنختار الخانة أو المجموعة لتلك الأرقام التي **تحت الإصبع**)، وبعد ذلك نسحب من المجتمع تلك العناصر التي يوافق رقمها الأرقام التي حصلنا عليها من الخانة المذكورة، حيث يجب الأخذ بالحسبان الأمور الآتية:

١- إذا كان الرقم الذي وقع عليه الاختيار يقع خارج نطاق الأرقام المستخدمة في ترقيم عناصر المجتمع، فإنه يُعدُّ لاغياً، ونتابع السحب باستخدام الرقم الذي يليه.

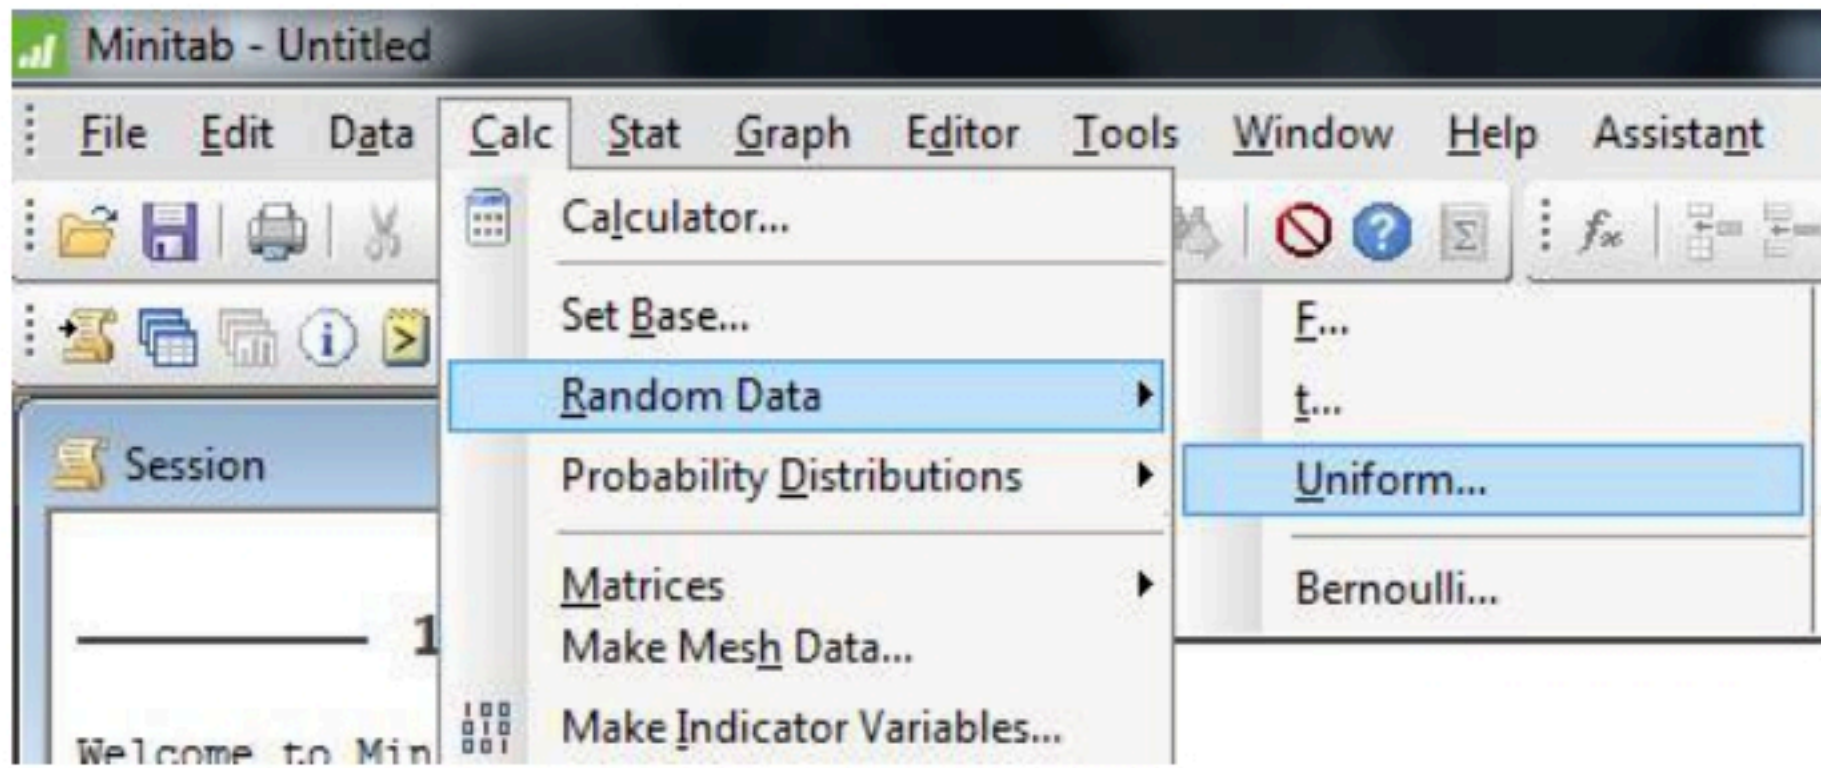
٢- إذا كنا مهتمين بالسحب دون الإعادة فإنَّ الرقم الذي وقع عليه الاختيار يُعدُّ لاغياً إذا كان هذا الرقم هو تكرار لرقم سابق تمَّ سحبه، فعلى سبيل المثال لو كان لدينا مجتمعاً إحصائياً حجمه $N = 132$ وأردنا سحب عينة عشوائية بدون إعادة باستخدام جدول الأرقام العشوائية وعلى أن يكون حجمها يساوي $n = 10$ ، فعندئذ نختار جدولاً تكون فيه الأرقام بثلاث خانات على الأقل، وليكن النموذج الآتي الذي يحتوي أرقاماً بخمس خانات:

56087 40875 13351 93994	39941 21225 93629 41469	93994 36009 76548 05393
22375 00953 22375 00953	16812 81542 04231 40875	67701 85423 60698 01898
00619 85423 60698 01898	41383 31555 12639 82667	64109 09497 76235 16210
61414 83525 76548 05393	74624 36348 77319 73408	89717 65997 02760 24359
96770 22909 29563 44018	58993 99410 48245 56087	36009 76548 05393 67705
64732 93589 61098 04393	22375 00953 22375 00953	71565 33413 81652 45554
48245 56087 40875 13351	04231 40875 13351 93994	56087 40875 13351 93994
52975 58993 99410 48245	10081 04231 40875 13351	86576 86944 93296 66456
56087 41383 31555 12639	93994 73152 14511 85285	47679 66810 41045 82830

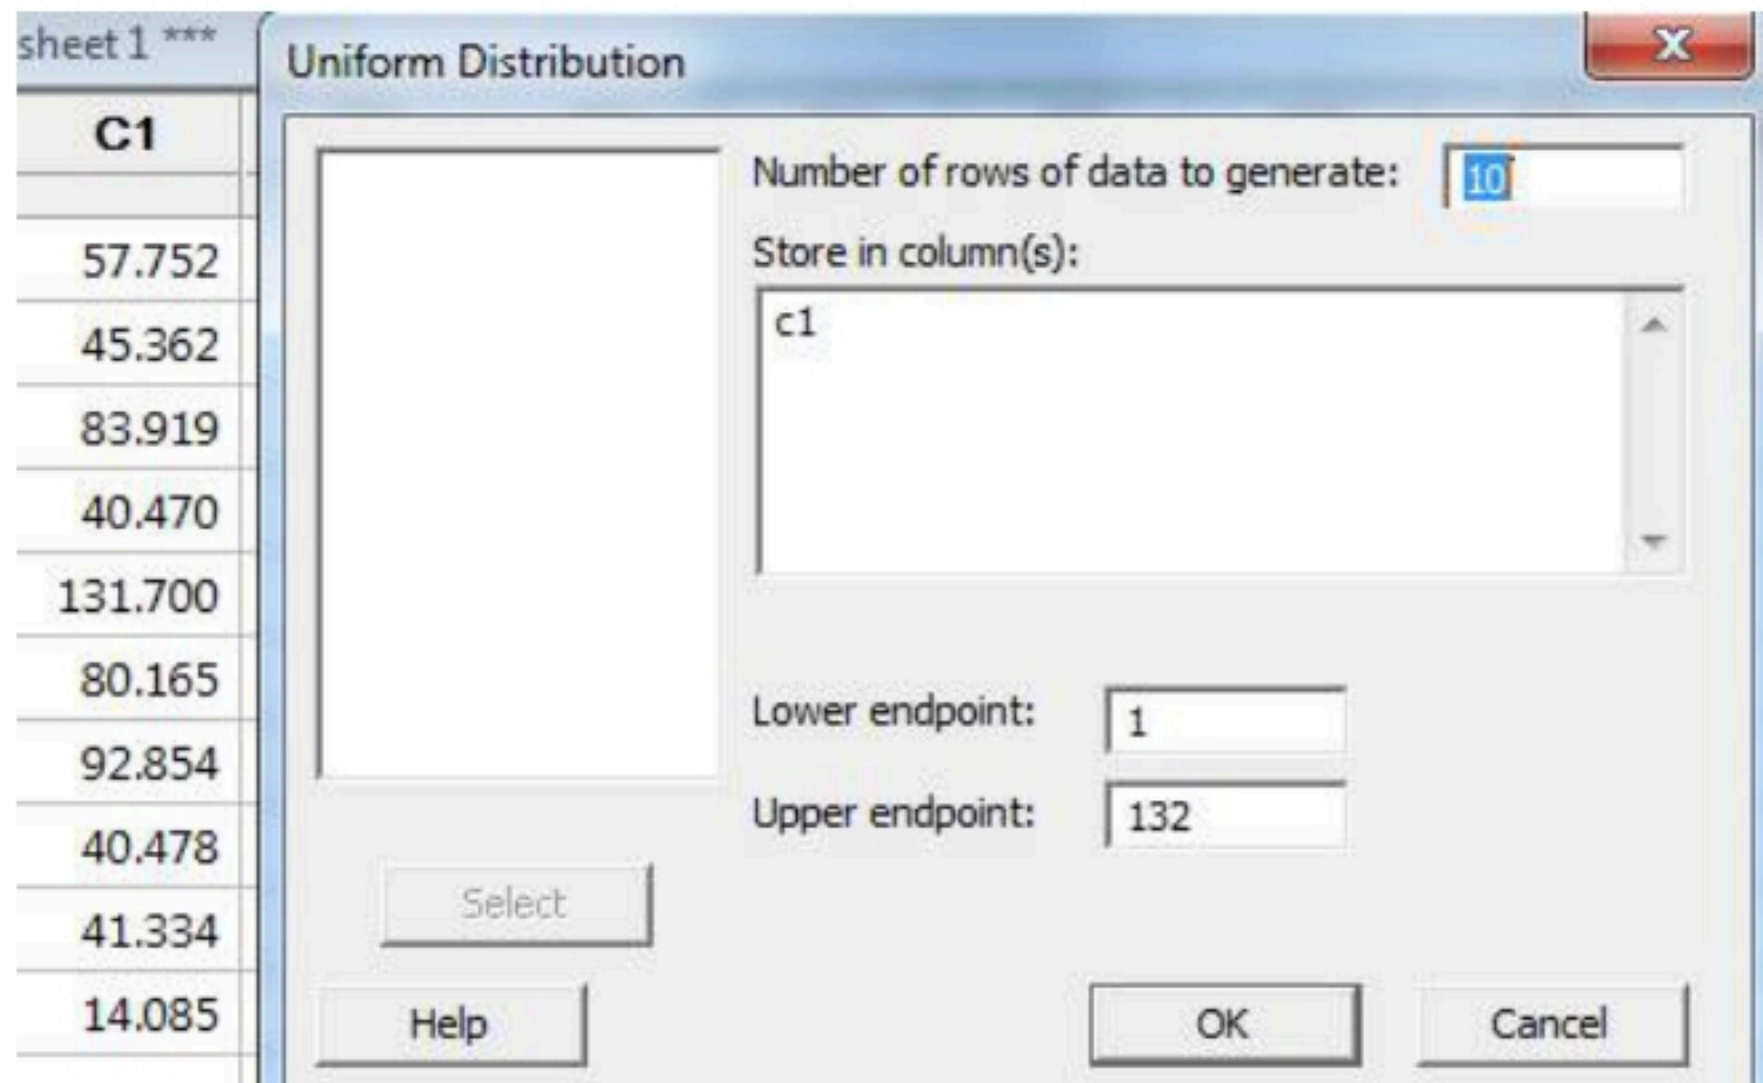
ثمّ لنختَر عشوائياً أحد هذه المجموعات، ولتكن على سبيل المثال المجموعة المحاطة بالمنحنى المغلق، فعندئذ أول عنصر يجب سحبه يحمل الرقم 41 (لأنّ الرقم 413 غير مستخدم في الإطار)، والعنصر الثاني رقمه 31، والثالث 126، وعلى هذا النحو نتابع السحب فتكون أرقام العناصر التي يجب أن تسحب من المجتمع موافقة للأرقام الآتية:

41 31 126 82 74 36 77 73 58 99

كما يمكننا استخدام بعض البرامج الإحصائية لتوليد القيم العشوائية لسحب عينة عشوائية ومنها على سبيل المثال برنامج Minitab وذلك من خلال استخدام الخطوات الموضحة في العرض الآتي:



فنحصل على اللوحة التالية التي نحدّد فيها حجم المجتمع والعينة والعمود الذي ستخزن عليه الأرقام المولدة.



فنحصل على القيم المعروضة في القسم الأيسر التي تُقَرَّب إلى أقرب عدد صحيح (لأنّ القيم المستخدمة في الإطار هي قيم صحيحة) فنجد العناصر التي يجب سحبها من المجتمع هي تلك العناصر التي تحمل الأرقام الآتية:

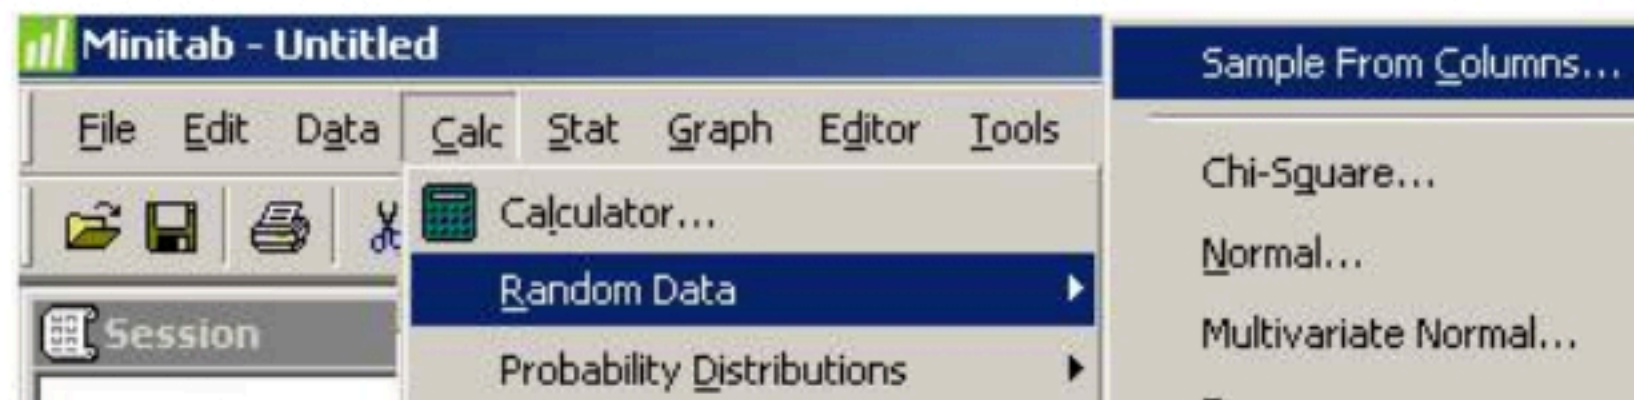
58 45 83 40 132 80 93 40 41 14

سنقوم فيما يلي بتقديم بعض أهم أنواع العينات العشوائية، ونبدأها بالعينة العشوائية البسيطة.

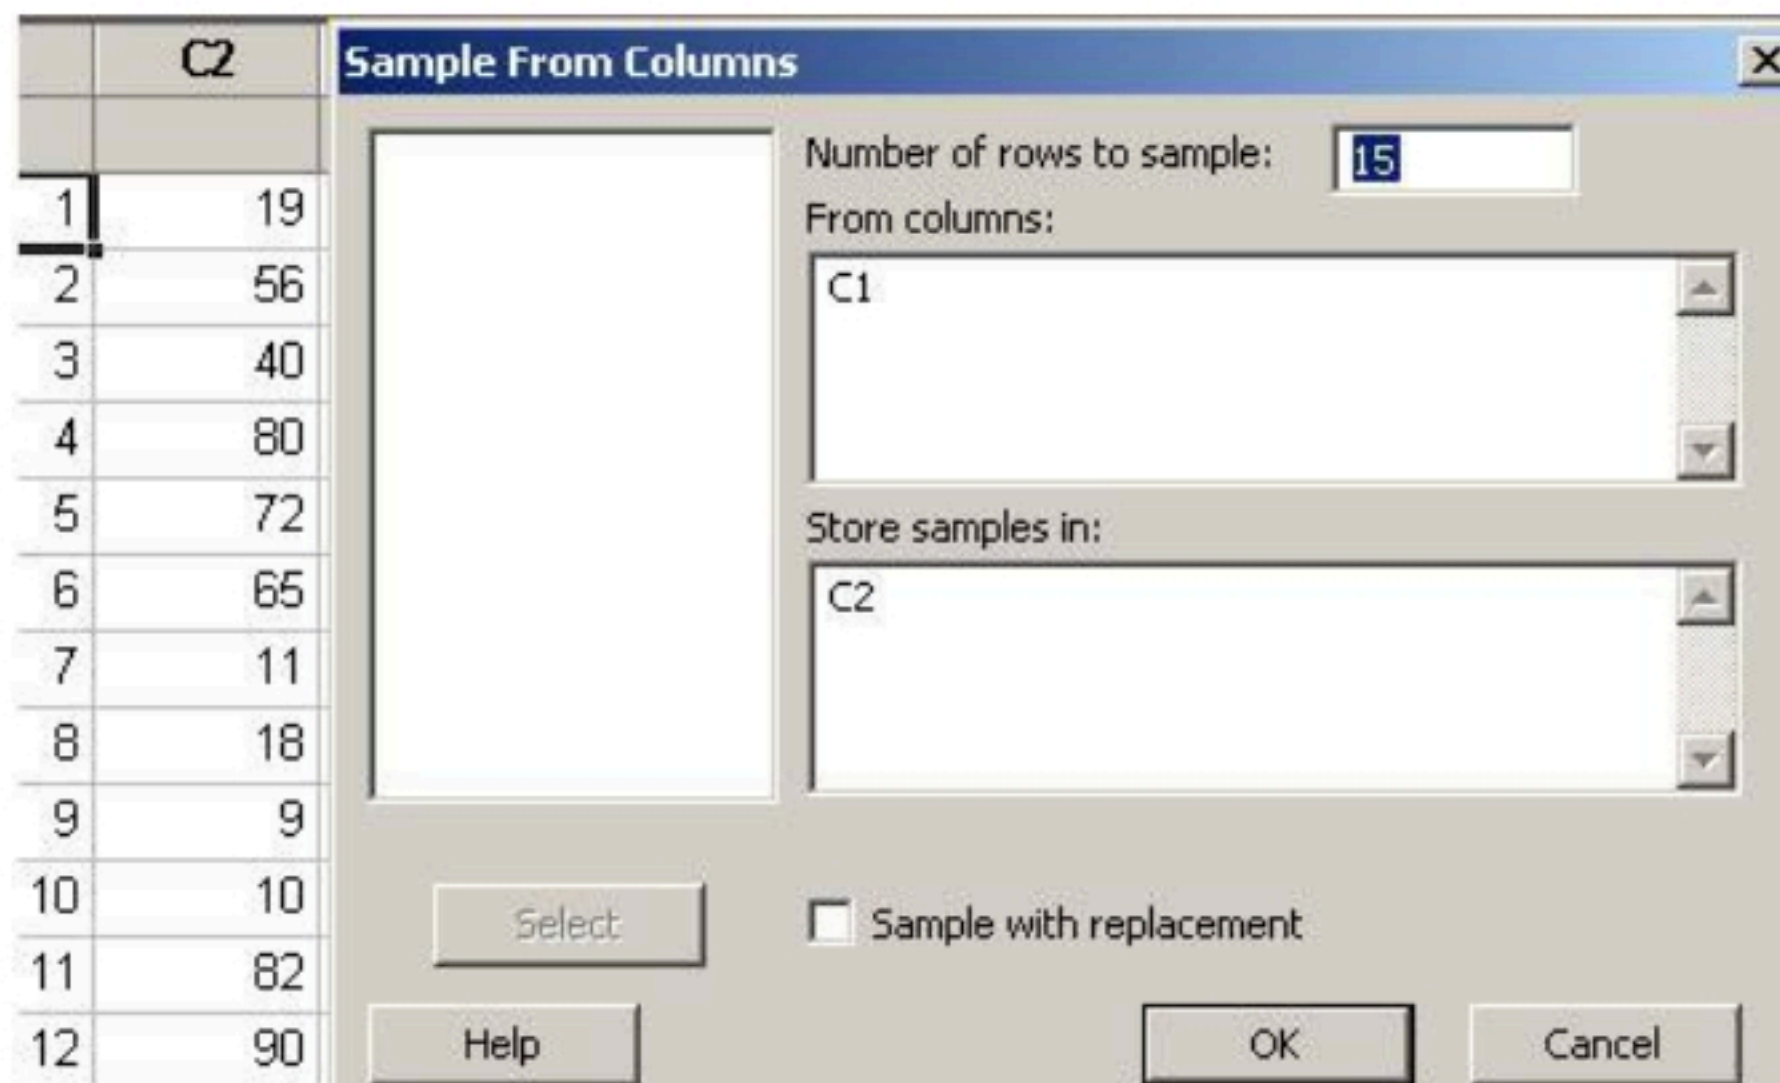
Simple Random Sample العينة العشوائية البسيطة (١, ٢, ٩)

يتميز هذا النوع من العينات العشوائية بأن لجميع عناصرها النصيب نفسه في الانتقاء مع أية عينة عشوائية أخرى لها الحجم نفسه وممكنة التشكيل من المجتمع نفسه، وهذا يوافق الحالة التي يكون فيها جميع عناصر المجتمع مستقلة بعضها عن بعض ولها النصيب نفسه في الظهور، ولتوضيح ما سبق لنأخذ طلبة جامعة ما X كمجتمع إحصائي، ولنفترض أننا بصدد تعيين متوسط طول الطلبة في هذه الجامعة، وأن جميع الطلبة لهم النصيب نفسه في الاختيار، وكما هو معلوم طول أي طالب لا يتأثر بطول الطلبة الآخرين فرادى كانوا أم جماعات، فعندئذ إذا قمنا بسحب عشوائي لـ n طالب من طلبة هذه الجامعة، فإن هذه العينة المسحوبة هي عينة عشوائية بسيطة؛ وذلك لأن أية عينة عشوائية أخرى ستسحب من هذا المجتمع ولها الحجم نفسه سيكون لها الاحتمال نفسه في انتقاء العينة السابقة.

كما يمكن استخدام برنامج Minitab لتوليد عينات عشوائية بسيطة وفقاً للطريقة المقدمة سابقاً أو من خلال تدوين أرقام العناصر في أحد الأعمدة ومن ثم طلب توليد عينة عشوائية من البيانات المدونة بالحجم المطلوب، فلو افترضنا أنه لدينا مجتمع حجمه $N = 100$ وأردنا سحب عينة عشوائية بسيطة منه بحجم $n = 10$ ، فعندئذ نحصل على أرقام عناصر هذه العينة باستخدام الأمر Calc من شريط الأوامر ومن ثم الانتقال إلى Random Data وبعد ذلك اختيار Sample Form Column ومن ثم اتباع الخطوات كما في العرضين الآتيين.



ومن ثم



فنحصل نتيجة لذلك أن عناصر العينة العشوائية البسيطة التي تحمل الأرقام الآتية:

19 56 40 80 72 65 11 18 9 10 82 90 37 71 39

Systematic Sample (أو المنتظمة) (٩, ٢, ١, ٢)

إنَّ هذا النوع من العينات العشوائية يقوم على الأسس الآتية:

١- إعطاء جميع أفراد المجتمع أرقاماً متسلسلة بدءاً من الواحد.

٢- تحديد قيمة عددية s تمثل طول فترة تدعى **فترة السحب** ومُعطاة من خلال العلاقة الآتية:

$$s := \left\lceil \frac{N}{n} \right\rceil \quad [9,1]$$

علماً أنَّ N و n يمثل حجم المجتمع والعينة على الترتيب، وأما $\lceil x \rceil$ فهو أصغر عدد صحيح أكبر من x حيث يشترط هنا أن يكون حجم المجتمع محدوداً وذلك لأنه عندما يكون حجم المجتمع غير محدود فإنَّ العلاقة الأخيرة تفقد معناها.

٣- سحب عشوائي لعنصر من المجتمع يكون رقمه u واقعاً بين الواحد و s (أي إنَّ $1 \leq u \leq s$ وذلك وفقاً لإحدى الطرائق العشوائية المتوفرة لدينا)، وهذا العنصر يدعى **عنصر البدء** Initial Element.

٤- أخذ بقية عناصر العينة من عناصر المجتمع التي رقمها يوافق العدد $u + k \cdot s$ مع $N_{n-1} \ni k$.

لتوضيح ذلك لنفترض أنَّه طلب منا حساب متوسط عدد الكلمات في كل صفحة من كتاب يحوي 420 صفحة مرقمة بـ 1 وحتى 420، وذلك باستخدام طريقة المعاينة الرتيبة على أن يكون حجم العينة $n = 19$. من أجل سحب مثل هذه العينة العشوائية نقوم أولاً بتعيين فترة السحب s فنجدها تساوي:

$$s = \left\lceil \frac{420}{19} \right\rceil = \lceil 22.105 \rceil = 23$$

وبعد ذلك نسحب وبشكل عشوائي رقماً يقع بين 1 والـ 23، وليكن على سبيل المثال الرقم 12، فعندئذ الصفحات ذات الرقم 12 هي عنصر البدء في العينة (صفحة البدء في العينة)، ومن ثم تكون الصفحات ذات الرقم $12 + 23k$ مع $N_{10} \ni k$ هي:

12	35	58	81	104	127	150	173	196	219
242	265	288	311	334	357	380	403	426	

فنكون ذلك قد حصلنا على العينة الرتيبة التي سنستخدمها لتقديم متوسط عدد الكلمات في كل صفحة من صفحات الكتاب، حيث نقوم بعدد الكلمات في كل صفحة من هذه الصفحات التابعة للعينة، ومن ثمَّ حساب المتوسط للقيم الأخيرة فتكون هي القيمة الافتراضية لمتوسط عدد الكلمات في كل صفحة من صفحات هذا الكتاب.

Stratified Sample (العينة الطبقيّة) (٩, ٢, ١, ٣)

إنَّ هذا النوع من العينات العشوائية يقوم على الأسس الآتية:

١- تقسيم المجتمع إلى فئات بحيث تكون عناصر هذه الفئات متجانسة قدر المستطاع، وعندئذ تدعى كل فئة من هذه الفئات طبقة.

٢- سحب عينة عشوائية بسيطة من كل طبقة من هذه الطبقات حيث يمكن النظر إلى كل طبقة من هذه الطبقات على أنَّها مجتمع جزئي متجانس تقريباً، وأما حجم هذه العينات البسيطة فيُحدد وفقاً لمعايير مختلفة من أهمها:

أ- أن يكون وفقاً لنسبة مئوية مُحددة من تعداد عناصر كل طبقة.

ب- أن يكون للطبقات ذات التفاوت الأكبر بين عناصرها حجم عينة أكبر.

ج- أن يكون للعينات ذات التكلفة الأكبر حجم أصغر من تلك العينات ذات التكلفة الأقل.

لتوضيح ذلك لنفترض أننا نريد معرفة متوسط الدخل السنوي في بلد ما X وذلك بطريقة العينة الطبقيّة، فعندئذ نقوم بتجزئة المجتمع إلى طبقات، ولتكن على سبيل المثال

أ- طبقة الأشخاص الذين لهم متوسط دخل سنوي أقل من 1000 وحدة نقدية.

ب- طبقة الأشخاص الذين لهم متوسط دخل سنوي ما بين 1000 و 1500 وحدة نقدية.

ج- طبقة الأشخاص الذين لهم متوسط دخل سنوي ما بين 1500 و 2000 وحدة نقدية.

د - طبقة الأشخاص الذين لهم متوسط دخل سنوي أكثر من 2000 وحدة نقدية.

فلو افترضنا أن هذه الطبقات على الترتيب هي S_1 ، S_2 ، S_3 و S_4 ، فعندئذ نقوم بسحب عينات بسيطة من كل طبقة من هذه الطبقات لحساب متوسط الدخل فيها، فإذا لاحظنا أنه يوجد تفاوت واضح في حجم الطبقات السابقة، فعندئذ يجب أن نأخذ ذلك بالحسبان لدى تحديد حجم العينة المسحوبة من كل طبقة بحيث يكون متناسباً طردياً مع حجم تلك الطبقة، ويفضل استخدام ثابت التناسب المذكور آنفاً نفسه من أجل كل العينات، فإذا وجدنا (على سبيل المثال) أن حجم هذه الطبقات هو:

$$N_1 = 3 \times 10^6 \quad \& \quad N_2 = 4 \times 10^6 \quad \& \quad N_3 = 2 \times 10^6 \quad \& \quad N_4 = 10^6$$

فعندئذ يفضل أخذ حجم العينات كنسبة مئوية من تعداد كل طبقة، كأن نأخذ 0.01% من كل طبقة، فيكون حجم العينة الواجب سحبها من الطبقة S_1 ، S_2 ، S_3 و S_4 على الترتيب هو $n_1 = 300$ ، $n_2 = 400$ ، $n_3 = 200$ و $n_4 = 100$ ، ومن ثم يحسب متوسط الدخل السنوي للفرد في كل عينة من هذه العينات، ثم أخذ المتوسط للقيم التي حصلنا عليها، فتكون هذه القيمة الأخيرة هي (على وجه التقريب) الممثل لمتوسط الدخل السنوي للفرد في هذا المجتمع وفقاً للمعينة الطبقة.

(٤، ١، ٢، ٩) العينة العنقودية Cluster Sample

يقوم الباحث بتكوين العينة في هذا النوع من العينات على عدة مراحل، وذلك على النحو الآتي:

١- تقسيم المجتمع إلى فئات متجانسة قدر الإمكان، وهذا التقسيم إما أن يكون افتراضياً أو أن يكون مفروضاً وفقاً لطبيعة المسألة ونوعية المجتمع المدروس.

٢- تقسيم الفئات السابقة إلى فئات جزئية متجانسة قدر الإمكان، وهذا التقسيم إما أن يكون افتراضياً أو أن يكون مفروضاً وفقاً لطبيعة المسألة، ومن الممكن أن يكون هناك تقسيمات جزئية أخرى لهذه الفئات الجزئية الأخيرة أيضاً.

٣- أخذ عينة عشوائية (بسيطة أو منتظمة) من كل فئة من هذه الفئات الجزئية الأخيرة.

٤- دمج العينات الأخيرة في عينة واحدة لتشكيل العينة المطلوبة.

لتوضيح ذلك لنفترض أننا نريد دراسة الوضع المعاشي في مدينة ما X مع ضواحيها بطريقة المعينة العنقودية.

نقوم أولاً بتقسيم المجتمع إلى فئات متجانسة قدر الإمكان، كأن نضع السكان المقيمين في مركز المدينة في فئة (طبقة) C_1 ، والسكان المقيمين على أطراف المدينة في فئة (طبقة) C_2 ، وسكان الأرياف القريبة ومتساوية البعد عن المدينة في فئة (طبقة) C_3 ، وهكذا مبتعدين عن المدينة حتى سكان الأرياف الأكثر بعداً ومتساوية البعد عن المدينة في فئة (طبقة) C_k الأخيرة. بعد ذلك نقوم بتجزئة كل فئة عدد من الفئات (على سبيل المثال إلى ثلاث فئات: الموظفين، والمقاولين، وأصحاب المهن الحرة)، ومن الممكن أن نلجأ إلى تقسيم كل فئة من الفئات الأخيرة إلى فئات جزئية أخرى (كأن نقسم فئة الموظفين إلى موظفين الدرجة الأولى، وموظفين الدرجة الثانية، ... وموظفين الدرجة الخامسة)، وبالمثل بالنسبة إلى بقية الفئات إن كان ذلك ممكناً وواجباً من أجل الدراسة. بعد ذلك نسحب عينة عشوائية (بسيطة أو منتظمة) من كل فئة من الفئات الأخيرة، وأخيراً نقوم بدمج العناصر التي حصلنا عليها في فئة واحدة لتكون العينة العشوائية العنقودية المطلوبة.

بالطبع من الممكن أن تتم عملية المعينة هذه على عدد أكبر من المراحل كأن يكون هناك تجزئة لكل من فئات الموظفين (كأن نجزئها إلى: موظفين ميدانيين، وإداريين، ...) والمقاولين (كأن نجزئها إلى: مقاولين للبناء، ومقاولين للطرق، ومقاولين للكهرباء، ...) وأصحاب المهن الحرة (كأن نجزئها إلى: مهنة السباكة، ومهنة إصلاح السيارات، ومهنة النجارة ...) أيضاً.

نكتفي بهذا القدر من التقديم حول بعض النماذج من العينات العشوائية؛ وذلك بسبب كثرة نماذجها التي لا يمكن تغطيتها في هذه العجالة من التقديم حيث يمكن لمن يود الاطلاع على المزيد الرجوع إلى المراجع ذات الصلة.

(٩, ٢, ٢) العينات العمدية (أو القصدية) Intentional Samples

إنَّ العينات العمدية هي عينات غير عشوائية (وكما هو واضح من تسميتها) تقوم على التدخل الشخصي للباحث في انتقاء عناصر العينة معتمداً في ذلك خبراته وحده، ولهذا لا يمكننا استخدام نظرية الاحتمالات والإحصاء الرياضي في تعميم النتائج التي نتوصل إليها من العينة على المجتمع، ولكن هذا لا يعني أنها عديمة الفائدة وذلك لأنه من الممكن أن تلعب دوراً مهماً في بعض الحالات. وفيما يلي نقدم بعض هذه النماذج، ولكن بشكل موجز وسريع، ومن أهمها:

(٩, ٢, ٢, ١) عينات الحصص Quota Samples:

في هذا النوع من العينات يقوم الباحث بانتقاء فئات معينة من المجتمع، وبحيث يُحدد لكل فئة حصة معينة لأجل اختيار عناصر العينة التي سيتم دراستها، وهكذا نلاحظ أنَّ هذا النوع من العينات يشابه نموذج العينات العشوائية الطبقة باستثناء غياب عامل العشوائية، فعلى سبيل المثال لدى التحقيق في قضية ما يوزع لكل مُحقق جمع معلومات من عدد محدد سلفاً من الأفراد، ولكن يتم ترك اختيار الأفراد وفقاً لطلب المحققين، فعندئذ العينة التي خضعت للتحقيق هي من نوع عينات الحصص.

(٩, ٢, ٢, ٢) العينات المنتقاة Selected Samples

في هذا النموذج من العينات يقوم الباحث بانتقاء عناصر معينة من المجتمع اعتقاداً منه أنَّ هذه العناصر مُثَّلة للمجتمع بشكل جيد، وهذا الانتقاء للعناصر ليس له مقياس مُحدد إذ إنَّ ذلك يعتمد على خبرة ومهارة الباحث. هذا وتجدر الملاحظة هنا إلى أنَّ هذا النوع من العينات قد يعطي نتائج أكثر دقة من النموذج السابق عندما يتعلق الأمر بتقدير المتوسط للظاهرة المدروسة، في حين أنَّ النتائج المتعلقة بتشتت الظاهرة التي قيد الدرس ستكون أقل إرضاءً مما هو عليه الحال لدى دراسة المتوسط.

(٩, ٢, ٢, ٣) العينات الكبيرة الحجم High-Size Samples

إنَّ هذا النموذج من العينات مبني على أساس سحب عينات كبيرة بالقدر المستطاع، وذلك بغض النظر عن نوعية العناصر المسحوبة من المجتمع، ويرر الباحثون هذا الأسلوب من خلال الكم الكبير للمعلومات التي سيحصلون عليها من العينات التي يُفترض أنَّ تعطي تصوراً أكثر دقة بخصوص الظاهرة المدروسة. بالطبع هذا الطرح يكون مقبولاً إلى حدٍّ ما عندما يكون المجتمع محدوداً وحجم العينة قريب من حجم المجتمع.

توجد أنواع أخرى كثيرة من العينات غير العشوائية مثل عينات **كرة الثلج** و **العينات الملائمة** ... حيث يمكن لمن يود الاطلاع على المزيد الرجوع إلى المراجع التي تبحث في نظرية المعاينة.

(٩, ٢, ٢, ٣, ١) ملاحظات

- ١- يجب الحذر لدى التعامل مع نتائج العينات غير العشوائية، وذلك بسبب عامل التحيز الذي يمكن أن يحدث من قبل الباحث.
- ٢- هنا نود الإشارة إلى أنه لا يوجد مقياس لتحديد حجم العينة المسحوبة إن كان كبيراً أو صغيراً، إذ إنَّ ذلك يتوقف على طبيعة المجتمع المدروس، ونوعية الظاهرة التي قيد الدرس، وكذلك على الإمكانيات المتوفرة لدى الباحث، ولكن اتفقنا مجازياً على أنَّ العينات التي يكون حجمها $n \leq 32$ تعدّ من فئة العينات الكبيرة (وَضَحنا السبب في الفصل الأول)، وأما العينات التي يكون حجمها $n > 32$ فإنَّها تُصنّف كعينات صغيرة، ولكنَّ هذا العدد /32/ المتفق عليه قابل للتعديل أحياناً حسب طبيعة المسألة المدروسة ومتطلباتها، وكذلك وفقاً للإمكانيات المتوفرة لدى الباحث.

- ٣- سنركز دراستنا المقبلة على استخدام العينات العشوائية (والبسيطة منها خصوصاً)، ومن ثمَّ يجب أن نتحقق الشروط الآتية في كلٍّ من المجتمع والعينة:

- أ- يجب أن يكون المجتمع الذي ستسحب منه العينة متجانساً إلى أقصى حد ممكن بخصوص المسألة المدروسة.
 - ب- يجب أن تكون جميع عناصر المجتمع الذي ستسحب منه العينة مستقلة بعضها عن بعض (لا تأثير لعنصر على آخر).
 - ج- يجب أن يتم سحب عناصر العينات من المجتمع بطريقة عشوائية (دون التحيز لعنصر على حساب عنصر آخر).
- ٤- فيما يلي، وعندما نذكر كلمة "عينة"، فإننا نقصد بذلك عينة عشوائية ما لم نشير إلى خلاف ذلك صراحةً، وكذلك عندما نذكر كلمة مجتمع فإننا نقصد بذلك أنه مجتمع إحصائي.

(٩,٣) البناء الرياضي للنظري للعينة العشوائية البسيطة

Random Simple Sample

لقد ذكرنا فيما سبق الشروط الواجب توافرها حتى نحصل على عينة بسيطة، ولكن على أرض الواقع يُنظر بعين الشك إلى النتائج التي نحصل عليها من سحب عينة واحدة فقط، وذلك لأنه ما يدرينا أننا سنحصل على النتائج نفسها من عينة أخرى لها الحجم نفسه وتحت الشروط نفسها أيضاً؟

لتقديم إجابة على السؤال السابق يلجأ عادة إلى سحب عدد (كبير أو صغير، ذلك حسب الإمكانيات المتوفرة لدى الباحث) من العينات العشوائية ذات الحجم المتساوي، ومن ثم أخذ النتيجة المتمخضة عن جميع هذه العينات كنتيجة لعينة عشوائية ذات حجم مساو لحجم كل عينة من العينات السابقة، ولتوضيح ما سبق سنفترض أننا نريد معرفة متوسط الطول لمجتمع طلبة في جامعة ما بوساطة أخذ عينات بسيطة، فعندئذ نفترض أن Ω هي مجموعة كل الطلبة في هذه الجامعة (أي إن Ω تمثل مجتمع الطلبة في هذه الجامعة)، وأن لجميع الطلاب النصيب نفسه في الاختيار، وأنه لا تأثير لطالب على آخر بخصوص الظاهرة التي نود دراستها (قياس طول الطالب). عندئذ نقوم بسحب عينة $\{\omega_{11}, \omega_{12}, \dots, \omega_{1n}\}$ (حجمها يساوي n) من مجتمع الطلبة، ومن ثم نقوم بقياس طول كل طالب من هذه العينة بوساطة مسطرة (مُرَقَّمة بالسنتيمتر مثلاً) سنرمز لها بـ X ، فنحصل نتيجة لذلك على مجموعة من القيم العشوائية $\{x_{11}, x_{12}, \dots, x_{1n}\}$ لأنه لا يمكننا معرفة طول الطالب الذي سيخضع للقياس بشكل مسبق وبدقة، علماً أن x_{1i} مع $N_n \ni i$ هي القيمة الناتجة عن قياس طول الطالب ω_{1i} (ذي الرقم i في هذه العينة). بعد ذلك نسحب من مجتمع الطلبة عينة ثانية $\{\omega_{21}, \omega_{22}, \dots, \omega_{2n}\}$ (حجمها يساوي n أيضاً، والسحب قد يكون مع الإعادة أو بدون إعادة إذا كان حجم المجتمع كبيراً)، ومن ثم نقوم بقياس طول كل طالب من هذه العينة فنحصل نتيجة لذلك على مجموعة من القيم العشوائية $\{x_{21}, x_{22}, \dots, x_{2n}\}$ علماً أن x_{2i} مع $N_n \ni i$ هي نتيجة قياس طول الطالب ω_{2i} (ذي الرقم i في العينة الثانية). ثم نكرر هذه العملية من سحب العينات لـ m مرة، فنحصل من سحب العينة $\{\omega_{m1}, \omega_{m2}, \dots, \omega_{mn}\}$ على مجموعة من القيم العشوائية $\{x_{m1}, x_{m2}, \dots, x_{mn}\}$ علماً أن x_{mi} مع $N_n \ni i$ هي نتيجة قياس طول الطالب ω_{mi} (ذي الرقم i في العينة الأخيرة). فلو قمنا الآن بصب النتائج السابقة في جدول كما يلي:

الجدول (٩, ١)

		الملاحظة Observation						
		X_1	X_2	X_3	...	X_n		
Result of	First Sample	x_{11}	x_{12}	x_{13}	...	x_{1n}	لعينة الأولى	نتائج
	Second Sample	x_{21}	x_{22}	x_{23}	...	x_{2n}	لعينة الثانية	
	⋮ ⋮	⋮	⋮	⋮	⋮ ⋮ ⋮	⋮	⋮ ⋮	
	Last Sample	x_{m1}	x_{m2}	x_{m3}	...	x_{mn}	لعينة الأخيرة	

ووضعنا $x_i := g(x_{1i}, x_{2i}, \dots, x_{mi})$ من أجل كل $N_n \ni i$ بحيث تأخذ g كدالة مناسبة لهدف الدراسة الإحصائية (كأن تكون g

دالة المتوسط مثلاً)، فعندئذ يمكن النظر بعين الرضى إلى العينة التي مجموعة نتائجها $\{x_1, x_2, \dots, x_n\}$ كتمثيل جيد للمجتمع من أجل الظاهرة المطلوب دراستها، وذلك لأنها حصيلة العديد من العينات العشوائية المسحوبة من المجتمع نفسه ولها الحجم نفسه.

الآن لنرجع قليلاً إلى الشرح السابق لننظر ما الذي يمكننا استنتاجه؟

في الحقيقة نستنتج مما سبق ما يلي:

١- إن المتغير X (الممثل بالمسطرة) هو متغير عشوائي يصف المجتمع Ω بخصوص الظاهرة التي قيد الدراسة (فعلى سبيل المثال لو كان المجتمع طبيعياً فعندئذ سيكون له X توزيع طبيعي).

٢- إن القيم الواقعة في الصف الأول من الجدول السابق هي قيم ناتجة عن إخضاع عناصر العينة الأولى لهذا المتغير العشوائي X ، وهذا النقاش ساري المفعول من أجل بقية القيم الواقعة في الصفوف الأخرى من الجدول السابق.

٣- إن العناصر الموجودة في العمود الأول من ذلك الجدول يمكن النظر إليها على أنها قيم لمتغير عشوائي X_1 ، وكذلك يمكن النظر إلى قيم العمود الثاني، والثالث، ... والأخير على أنها قيم لمتغير عشوائي X_2, X_3, \dots, X_n على الترتيب.

٤- المتغيرات العشوائية X_1, X_2, \dots, X_n مستقلة عشوائياً، وهذا الاستقلال ناتج عن استقلال عناصر المجتمع بعضها عن بعض.

٥- المتغيرات العشوائية X_1, X_2, \dots, X_n متطابقة في التوزيع مع المتغير العشوائي X الواصف للمجتمع (الذي لعب دور أداة القياس)، وهذا التطابق حاصل من كون قيم هذه المتغيرات العشوائية ناتجة عن قيم المتغير العشوائي X نفسه.

هكذا نرى أن القيم الناتجة عن كل عينة من العينات السابقة هي قيم لمتجه عشوائي سنرمز له بـ $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ ، ومركباته تحقق الخواص $4/$ و $5/$ السابقة، ومن أجل n قيمة مثبتة فإن المتجه العشوائي \mathcal{X}_n يطبق على المجموعة Ω^n وفقاً للعلاقة الآتية:

$$\mathcal{X}_n : \Omega^n \longrightarrow \mathbb{R}^n ; (\omega_1, \omega_2, \dots, \omega_n) \mapsto \mathcal{X}_n(\omega_1, \omega_2, \dots, \omega_n) := (X_1(\omega_1), X_2(\omega_2), \dots, X_n(\omega_n))$$

(١، ٣، ٩) ملاحظات

١- من الممكن أن يكون عدد العينات العشوائية المسحوبة من المجتمع غير منته، ومن ثم تكون قيم المتغيرات العشوائية X_1, X_2, \dots, X_n غير منتهية أيضاً.

٢- إن المتغيرات العشوائية X_1, X_2, \dots, X_n تدعى **ملحوظات** (أو **ملاحظات**)، وأما القيم الناتجة عن هذه المتغيرات العشوائية فإنها تدعى **القيم الملحوظة** (أو **المشاهدة**) Observation Values للعينة، ويرمز لهذه القيم بأحرف صغيرة من قبيل x_1, x_2, \dots, x_n (على غرار ما استخدم في الاحتمالات).

٣- إن العينة العشوائية $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ التي تم بناؤها وفقاً للعرض السابق تدعى **عينة عشوائية بسيطة**.

٤- عندما نذكر مستقبلاً أنه لدينا عينة \mathcal{X}_n فإننا نقصد بذلك أنها عينة عشوائية بسيطة حجمها يساوي n ، وأن المتجه (x_1, x_2, \dots, x_n) الممثل لقيمة \mathcal{X}_n إنما هو نتيجة لتطبيق \mathcal{X}_n على متجه $(\omega_1, \omega_2, \dots, \omega_n)$ (الذي يمثل عينة حجمها n ستطبق عليها الدراسة الإحصائية) من Ω^n وفقاً للعلاقة:

$$\mathcal{X}_n(\omega_1, \omega_2, \dots, \omega_n) := (X_1(\omega_1), X_2(\omega_2), \dots, X_n(\omega_n))$$

ولذلك حتى لو لم تظهر عناصر العينة $(\omega_1, \omega_2, \dots, \omega_n)$ التي ستطبق عليها الدراسة في عرض العينة العشوائية \mathcal{X}_n فإنه يجب ألا يغيب عن ذاكرتنا أنها موجودة ضمناً في هذه الصيغة.

٥- في حال عدم ذكر حجم المجتمع أو عدم التنويه إلى ما يُدلل على ذلك فإننا نقصد بذلك مجتمعاً غير محدود أو كبير جداً بحيث إن عملية سحب العينات لا تؤثر في حجمه، وذلك بغض النظر عن الطريقة التي يتم فيها سحب العينة سواء كانت مع الإعادة أم بدون إعادة.

٦- عندما نذكر أنه لدينا مجتمع موصوف من خلال متغير عشوائي X فإننا نقصد بذلك أن التوزيع الاحتمالي لهذا المجتمع هو توزيع X نفسه، وأن أي عينة $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ مسحوبة من هذا المجتمع ستكون مولدة وفقاً للطريقة التي ذكرت سابقاً، ومن ثم يكون لجميع الملاحظات X_1, X_2, \dots, X_n توزيع المتغير العشوائي X نفسه أيضاً.

٧- عندما نذكر أن للمتغير العشوائي X (الواصف للمجتمع) دالة كثافة احتمالية $f_X(x; \theta)$ فإننا نقصد بذلك ما يلي:
أ- إذا كان X متغيراً عشوائياً مستمراً فإن $f_X(x; \theta)$ هي دالة الكثافة الاحتمالية نفسها التي عرفت سابقاً من أجل المتغيرات العشوائية المستمرة، وأن القيمة θ هي معلمة التوزيع الذي من الممكن أن يكون متجهاً ذا بعد منته.

ب- إذا كان X متغيراً عشوائياً متقطعاً بمجموعة قيم $X = \{x_i; i \in I\}$ فإن $f_X(x; \theta)$ هي دالة الكتلة الاحتمالية المعروفة سابقاً من أجل المتغيرات العشوائية المتقطعة، ولكنها كدالة بـ x_i و θ معاً، والمثالان الآتيان يوضحان هذه الملاحظة.

(٩, ٣, ٢) أمثلة

١- ليكن لدينا مجتمعاً طبيعياً بمتوسط μ وانحراف معياري σ ، فعندئذ يكون للمتغير العشوائي X الواصف لهذا المجتمع توزيع $N(\mu, \sigma)$ ، وأما دالة كثافته الاحتمالية $f_X(x; \theta)$ فلها العرض الآتي من أجل كل $x \in \mathbb{R}$:

$$f_X(x; \theta) = f_X(x; (\mu, \sigma)) = \frac{1}{\sigma \sqrt{2\pi}} \exp \left[-\frac{1}{2} \left(\frac{x - \mu}{\sigma} \right)^2 \right]$$

وهذا يعني أن المعلمة $\theta = (\mu, \sigma)$ هو متجه من $\mathbb{R} \times (0, \infty)$.

٢- ليكن لدينا مجتمعاً برنولياً معلمته p (احتمال النجاح)، فعندئذ يكون للمتغير العشوائي X الواصف لهذا المجتمع توزيع ثنائي النقطة في $x_1 = 1$ و $x_2 = 0$ (توزيع برنولي)، وأما دالة كثافته الاحتمالية $f_X(x; \theta)$ فلها العرض:

$$f_X(x; \theta) = f_X(x; p) = P(X = x) = p^x (1-p)^{1-x}; x = 0, 1$$

فلاحظ هنا أن المعلمة $\theta = p$ هو قيمة من الفترة $(0, 1)$.

(٩, ٤) النموذج الرياضي النظري لمجتمع إحصائي

Theoretical Mathematical Model for Population

لقد رأينا في فصول سابقة أنه من أجل كل تجربة عشوائية يمكننا إيجاد نموذج رياضي نظري يمثله ألا وهو الفضاء الاحتمالي $[\Omega, \mathcal{A}, P]$ الموافق لهذه التجربة العشوائية. كذلك الأمر بالنسبة إلى المجتمع، فمن أجل أي مجتمع يمكننا تعيين نموذج رياضي نظري يمثله، فلو كانت Ω (مجموعة غير خالية) هي مجموعة العناصر لمجتمع ما، و \mathcal{S} هو σ -جبر فوق Ω ، وأخيراً نأخذ $\mathcal{P} = \{P_\theta; \theta \in \Theta \subseteq \mathbb{R}^k\}$ أسرة قياسات احتمالية فوق $[\Omega, \mathcal{S}]$ ، علماً أن $N \ni k$ مثبت و θ متجه من \mathbb{R}^k ويدعى معلمة المجتمع.

تحت هذه الافتراضات يُطلق على الثلاثية $[\Omega, \mathcal{S}, \mathcal{P}]$ اسم النموذج الرياضي النظري للمجتمع الإحصائي.

(٩, ٤, ١) ملاحظات

١- مما سبق نلاحظ أن θ يمثّل معلمة المجتمع، ويمكن أن يكون متجهاً من \mathbb{R}^k عندما يكون $2 \leq k$.

- ٢- إن مجموعات عناصر العينات التي ستخضع للدراسة هي عناصر من σ - جبر \mathcal{S} .
- ٣- على سبيل التبسيط والاختصار سنستخدم عبارة "مجتمع $[\Omega, \mathcal{S}, \mathcal{P}]$ " عوضاً عن عبارة مجتمع بنموذج رياضي نظري $[\Omega, \mathcal{S}, \mathcal{P}]$ ما لم يؤدي ذلك إلى التباس في المعنى أو المدلول.
- ٤- نعلم أنه في النموذج الرياضي النظري $[\Omega, \mathcal{A}, P]$ لتجربة عشوائية يكون للقياس الاحتمالي P صيغة محددة (توزيع معين)، في حين أننا نجد في النموذج الرياضي النظري للمجتمع أن القياسات الاحتمالية P_0 تابعة لقيم المعلمة θ ، ومن ثم يجب جمع كل ما هو ممكن من معلومات حول θ لكي يصبح P_0 قياساً احتمالياً مناسباً للمجتمع المعطى، والأمثلة الآتية توضح لنا ذلك.
- أ- ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً طبيعياً بمعلمتين μ و σ ، أي إن هذا المجتمع موصوف من خلال متغير عشوائي X خاضع للتوزيع الطبيعي $N(\mu, \sigma)$ ، فعندئذ يكون لدينا:

$$\mathcal{P} = \{P_\theta; \theta \in \Theta\} = \{P_{(\mu, \sigma)}; (\mu, \sigma) \in \mathbb{R} \times (0, \infty)\}$$

ومن ثم يجب البحث في معرفة قيمة كل من المعلمتين μ و σ لكي يصبح $[\Omega, \mathcal{S}, \mathcal{P}]$ نموذجاً رياضياً مناسباً للمجتمع المعطى. إن قيمة كل من μ و σ مجهولة في الحالة العامة ولذلك علينا تقدير كل من μ و σ أو أحدهما إن كان الآخر معطى، علماً أن عملية التقدير هذه تتم باستخدام عينات عشوائية تُسحب من المجتمع.

ب- ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً أسياً بمعلمة λ ، $0 < \lambda$ ، أي إن هذا المجتمع موصوف من خلال متغير عشوائي X خاضع للتوزيع الأسى بمعلمة λ ، $0 < \lambda$ ، فعندئذ يكون:

$$\mathcal{P} = \{P_\theta; \theta \in \Theta\} = \{P_\lambda; \lambda \in (0, \infty)\}$$

ومن ثم يجب علينا معرفة قيمة λ أو تقديرها من عينات عشوائية تُسحب من المجتمع بحيث يصبح $[\Omega, \mathcal{S}, \mathcal{P}]$ نموذجاً رياضياً مناسباً لهذا المجتمع المعطى.

٥- يتبين لنا مما تقدم (في هذا الفصل وفي الفصول السابقة) أن الغاية من أخذ عينة من المجتمع المفترض قد يكون لها أكثر من هدف، ومنها على سبيل المثال لا الحصر:

أ- الحصول على معلومات حول توزيع هذا المجتمع الذي يعبر عنه بوسائط عدة منها على سبيل المثال جدول التوزيع التكراري، المدرج التكراري، المضلع التكراري أو....

ب- معرفة بعض القيم الكمية المميزة المتعلقة بالمجتمع مثل: المتوسط، التباين، الالتواء أو....

إن عملية الحصول على هذه المعلومات تتم عادة من خلال تقديرها بقيم مستحصل عليها من العينات العشوائية المسحوبة من المجتمع المفترض، ولكن الوصول إلى هذه الغاية بشكل علمي معقول يتطلب منا تقديم بعض التعاريف والدراسات التي سنقدم بعضها على مدى القسم المتبقي من هذا الفصل.

(٩,٥) الإحصاءات ودوال توزيع العينات

Statistics and distribution functions of samples

يقدم لنا التعريف الآتي مفهوم الإحصاء أو ما يُعرف باسم دالة العينة Sample Function أيضاً.

(٩,٥,١) تعريف (الإحصاء Statistic)

ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X ، ولناخذ \mathcal{X}_n عينة من هذا المجتمع، وبفرض أن g دالة حقيقية

معرفة على \mathbb{R}^n وقيوسة بالنسبة إلى \mathfrak{R} و \mathfrak{R}^n ، فعندئذ يُطلق على المتغير العشوائي $(\mathcal{X}_n) := g(T)$ اسم **إحصاءة** Statistic أو **دالة عينة** Sample Function (سنستخدم في سياق دراستنا المقبلة عبارة "إحصاءة" للدلالة على الدالة $g(\mathcal{X}_n)$). فيما يلي نقدم بعض النماذج الشهيرة من الإحصاءات.

(١, ١, ٥, ٩) أمثلة

ليكن $[\Omega, \mathfrak{S}, \mathfrak{P}]$ مجتمعاً، ولناخذ $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ عينة مسحوبة من هذا المجتمع، وبفرض أن g دالة حقيقية معرفة على \mathbb{R}^n وقيوسة بالنسبة إلى \mathfrak{R} و \mathfrak{R}^n (جميع الدوال التي سنقدمها في هذا المثل قیوسة بالنسبة إلى \mathfrak{R} و \mathfrak{R}^n)، فعندئذ:

١- إذا أخذنا g دالة بالعينة \mathcal{X}_n ومعرفة من خلال العلاقة الآتية:

$$g(\mathcal{X}_n) = \frac{1}{n} \sum_{i=1}^n X_i$$

فإن هذه الإحصاءة تدعى **متوسط العينة** Mean of Sample \mathcal{X}_n ، وكنا قد رمزنا لها سابقاً (انظر العلاقة [8-11-a] في الفصل الثامن) بـ \bar{X}_n حيث كانت قيمة n تتحول على كل قيم N ، ولكن بسبب أن قيمة n هنا مثبتة (من أجل عينة مُحَدَّدة الحجم) فإننا سنستخدم الرمز \bar{X} بدلاً من \bar{X}_n ما لم يؤدي ذلك إلى التباس، أي إنه لدينا:

$$\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n} \quad [9,2]$$

وأما قيمة هذه الإحصاءة فسوف نرمز لها بـ \bar{X} لكي يتفق مع ما تم تقديمه سابقاً.

٢- إذا أخذنا g كدالة بالعينة ومعرفة من خلال العلاقة الآتية:

$$g(\mathcal{X}_n) = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

فعندئذ تدعى هذه الإحصاءة **تباين العينة** Variance of Sample \mathcal{X}_n (أو التباين العملي الذي قدم في الفصل الثاني من أجل مجموعة من البيانات)، ويرمز له بـ S_X^2 ، أي إنه لدينا:

$$S_X^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \quad [9,3]$$

وأما قيمة هذه الإحصاءة فيرمز لها بـ S_X^2 ، وفي حال عدم الوقوع في التباس (كأن تكون الدراسة متعلقة بمجتمع وحيد) فإننا سنكتب S^2 و s^2 عوضاً عن S_X^2 و s_X^2 وذلك على سبيل التبسيط.

إن الجذر التربيعي الموجب لتباين العينة يدعى **الانحراف المعياري للعينة** ويرمز له بـ S_X ولقيمته بـ s_X ، وفي حال عدم الوقوع في التباس يكتب S و s فقط على سبيل التبسيط.

٣- إذا أخذنا g دالة بالعينة \mathcal{X}_n ومعرفة من خلال العلاقة الآتية:

$$g(\mathcal{X}_n) = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

وسنرمز لهذه الإحصاءة بـ \tilde{S}_X^2 ، وهنا نلاحظ أن صيغة هذه الإحصاءة توافقت الصيغة النظرية للتباين في الاحتمالات، وكذلك توافقت صيغة التباين لبيانات مجتمع (كما مر معنا في الفصل الثاني من هذا الكتاب)، وهي بالفعل صيغة تباين للعينة أيضاً (ولكنها ليست التباين العملي)، ولكي لا تلبس هذه التسمية مع تسمية تباين العينة S^2 سنكتفي بتسميتها بالإحصاءة \tilde{S}^2 فقط، وفي حال عدم الوقوع في التباس فإننا سنكتب \tilde{S}^2 فقط، وأما قيمة هذه الإحصاءة فسوف نرمز لها بـ \tilde{S}^2 . أي إنه لدينا:

$$\tilde{S}_X^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \quad [9,4]$$

نشير هنا إلى أن الجذر التربيعي الموجب لـ \tilde{S}^2 يدعى **الانحراف المعياري** أيضاً وسنرمز له بـ \tilde{S} ، وأما قيمته فسوف نرمز لها بـ \tilde{s} ، وكذلك نلاحظ أن العلاقة التي تربط بين S^2 و \tilde{S}^2 هي:

$$\tilde{S}^2 = \frac{n-1}{n} S^2 \quad [9,5]$$

وذلك لأن:

$$\tilde{S}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{n-1}{n} \left[\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \right] = \frac{n-1}{n} S^2$$

ومن ثم يكون لدينا:

$$S^2 = \frac{n}{n-1} \tilde{S}^2 \quad [9,6]$$

٤- إذا أخذنا g دالة بالعينة \mathcal{X}_n ومعرفة من خلال العلاقة الآتية:

$$T = g(\mathbb{X}_n) = \frac{1}{n} \sum_{i=1}^n X_i^k$$

علماً أن $k \in \mathbb{N}$ ، فعندئذ هذه الإحصاءة تدعى **العزم من المرتبة k للعينة \mathcal{X}_n** ، وسنرمز لها بـ $\mathbf{M}_X^{(k)}$ وفي حال عدم الوقوع في التباس سنكتب $\mathbf{M}^{(k)}$ فقط على سبيل التبسيط، أي إنه لدينا:

$$\mathbf{M}^{(k)} = \frac{X_1^k + X_2^k + \dots + X_n^k}{n} \quad [9,7]$$

وأما قيمة هذه الإحصاءة فسنرمز لها بـ $\mathbf{m}^{(k)}$ ، ومن أجل $k=1$ سنكتب $\mathbf{M}^{(1)} = \mathbf{M}$ وكذلك $\mathbf{m}^{(1)} = \mathbf{m}$.

(٩, ٥, ٢) تعريف (دالة التوزيع العملية للعينة) Empirical Distribution Function of Sample

ليكن $[\Omega, \mathcal{F}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X ، ولناخذ \mathcal{X}_n عينة من هذا المجتمع، ولنعرّف من أجل هذه العينة دالة حقيقية $F_{n,\omega}$ على \mathbb{R} كما يلي:

$$F_{n,\omega} : \mathbb{R} \longrightarrow [0, 1] ; x \mapsto F_{n,\omega}(x) := \frac{1}{n} \sum_{i=1}^n \mathbf{I}_{(-\infty, x)}(X_i(\omega_i)) \quad [9,8-a]$$

فعندئذ يُطلق على الدالة $F_{n,\omega}$ اسم **دالة التوزيع العملية للعينة \mathcal{X}_n** ، علماً أن $\omega = (\omega_1, \omega_2, \dots, \omega_n)$ هي تلك الأفراد من المجتمع التي طُبّق عليها المتجه العشوائي \mathcal{X}_n في الدراسة الإحصائية.

في الحقيقة يمكن عرض الدالة $F_{n,\omega}$ بالشكل المكافئ الآتي أيضاً:

$$F_{n,\omega}(x) = \frac{1}{n} \sum_{i=1}^n \mathbf{I}_{(-\infty, x)}(x_i) \quad [9,8-b]$$

حيث نلاحظ أن قيمة هذه الدالة عند نقطة $x \in \mathbb{R}$ تساوي عدد عناصر العينة التي لها قيم أصغر من x مضروبة بـ n^{-1} .

إن المبرهنة الآتية التي سنقبلها دون برهان، وترجع إلى الرياضياتي الروسي **غليفينكو** (وتعرف باسم **Glivenko–Cantelli**)

theorem أيضاً)، تبين أن متتالية دوال توزيع العينة تتقارب من دالة توزيع المجتمع (بانتظام) عندما يسعى حجم العينة إلى اللانهاية.

(٩, ٥, ٢, ١) مبرهنة (غليفيكو)

ليكن $[\Omega, \mathcal{F}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X وبدالة توزيع احتمالية F_X ، ولناخذ \mathcal{X}_n عينة مسحوبة من هذا المجتمع بدالة توزيع عملية $F_{n,\omega}$ ، فعندئذ تكون العلاقة الآتية محققة:

$$P \left(\lim_{n \rightarrow \infty} \sup_{x \in \mathbb{R}} |F_{n,\omega}(x) - F_X(x)| = 1 \right) = 1 \quad [9,9]$$

(٩, ٥, ٢, ٢) ملاحظات

١- من التعريف السابق نلاحظ أنه من أجل $x \in \mathbb{R}$ مثبتة فإن الدالة $F_{n,\omega}$ هي متغير عشوائي فوق Ω .

٢- من المبرهنة السابقة يتضح لنا أن متتالية دوال التوزيع العملية $(F_{n,\omega})_{n \in \mathbb{N}}$ متقاربة بانتظام من دالة توزيع المجتمع F_X وذلك باحتمال يساوي الواحد.

(٩, ٦) المميزات العددية لبعض الإحصاءات

Numerical Characteristics of Some Statistic's

بسبب الأهمية الكبيرة لبعض الإحصاءات، وعلى وجه الخصوص الإحصاءات \bar{X} ، S^2 و \tilde{S}^2 ، فإننا سنقوم بتقديم بعض المميزات العددية لها من خلال المبرهنة الآتية.

(٩, ٦, ١) مبرهنة

ليكن $[\Omega, \mathcal{F}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X ، ولنفترض أن متوسطه μ (أي إن $EX = \mu$) وتباينه σ^2 (أي إن $\text{var } X = \sigma^2$)، ولتكن \mathcal{X}_n عينة مسحوبة من هذا المجتمع، فعندئذ يكون لدينا ما يلي:

$$\text{a) } E \bar{X} = \mu \quad [9,10]$$

وهذا يعني أن التوقع الرياضي (القيمة الوسطى) للإحصاء \bar{X} مستقل عن حجم العينة.

$$\text{b) } \text{var } \bar{X} = \frac{\sigma^2}{n} \quad [9,11]$$

وهذا يعني أن قيمة تباين الإحصاء \bar{X} تتناسب عكسياً مع حجم العينة n ، ومن ثم قيمة تباينه ستتناقص بازدياد حجم العينة n .

$$\text{c) } E \tilde{S}^2 = \frac{n-1}{n} \sigma^2 \quad [9,12-a]$$

والتي نجد منها أن:

$$\text{d) } E S^2 = \sigma^2 \quad [9,12-b]$$

وهذا يعني أن التوقع الرياضي للإحصاء \tilde{S}^2 مرتبط بحجم العينة n ، في حين أن التوقع الرياضي للإحصاء S^2 مستقل عن حجم العينة.

$$\text{e) } \text{var } \tilde{S}^2 = \frac{\mu^4 - \sigma^4}{n} - 2 \frac{\mu^4 - 2 \sigma^4}{n^2} + \frac{\mu^4 - 3 \sigma^4}{n^3} \quad [9,13-a]$$

وهذا يعني أن قيمة التباين للإحصاءة \tilde{S}^2 مرتبطة عكسياً مع حجم العينة n ، ومن ثمَّ قيمة تباينه ستتناقص بازدياد حجم العينة n أيضاً.

$$\text{f) } \text{var} S^2 = \left(\frac{n}{n-1} \right)^2 \cdot \left(\frac{\mu^4 - \sigma^4}{n} - 2 \frac{\mu^4 - 2\sigma^4}{n^2} + \frac{\mu^4 - 3\sigma^4}{n^3} \right) \quad [9,13-b]$$

البرهان: سنقبل العلاقة [9,13-a] دون برهان، وأما العلاقتين [9,12-a] و [9,13-b] فإنَّهما تنتجان عن العلاقتين [9,12-a] و [9,13-b] على الترتيب لدى استخدام العلاقة [9,6] وخواص التباين. أما من أجل بقية العلاقات فإنَّه بسبب الاستقلال بين ملحوظات العينة X_1, X_2, \dots, X_n وتطابقها في التوزيع مع المتغير العشوائي X ، وكذلك باستخدام خصائص التوقع الرياضي والتباين يكون لدينا ما يلي:

$$\text{For a) } E\bar{X} = E \left(\frac{1}{n} \sum_{i=1}^n X_i \right) = \frac{1}{n} \sum_{i=1}^n E X_i = \frac{1}{n} n \cdot EX = \mu$$

$$\text{For b) } \text{var} \bar{X} = \text{var} \left(\frac{1}{n} \sum_{i=1}^n X_i \right) = \frac{1}{n^2} \sum_{i=1}^n \text{var} X_i = \frac{1}{n^2} n \cdot \text{var} X = \frac{\sigma^2}{n}$$

$$\begin{aligned} \text{For c) } E \tilde{S}^2 &= E \left(\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \right) = \frac{1}{n} E \left[\sum_{i=1}^n [(X_i - EX) + (EX - \bar{X})]^2 \right] \\ &= \frac{1}{n} E \left[\sum_{i=1}^n [(X_i - EX)^2 - 2(X_i - EX)(\bar{X} - EX) + (\bar{X} - EX)^2] \right] \\ &= \frac{1}{n} E \left[\sum_{i=1}^n (X_i - EX)^2 - 2(\bar{X} - EX) \sum_{i=1}^n (X_i - EX) + n(\bar{X} - EX)^2 \right] \\ &= \frac{1}{n} E \left[\sum_{i=1}^n (X_i - EX)^2 - 2(\bar{X} - EX) \sum_{i=1}^n (X_i - EX) + n(\bar{X} - EX)^2 \right] \\ &= \frac{1}{n} E \left[\sum_{i=1}^n (X_i - EX)^2 - 2(\bar{X} - EX) \left(\sum_{i=1}^n X_i - E \sum_{i=1}^n X_i \right) + n(\bar{X} - EX)^2 \right] \\ &= \frac{1}{n} \left[\sum_{i=1}^n E(X_i - EX)^2 - n E(\bar{X} - EX)^2 \right] \\ &= \frac{1}{n} (n \text{var} X_i - n \text{var} \bar{X}) = \frac{1}{n} \left(n \sigma^2 - n \frac{\sigma^2}{n} \right) = \frac{n-1}{n} \sigma^2 \end{aligned}$$

وبهذا يتم البرهان.

(٩, ٦, ٢) ملاحظات

١- في الحالة الخاصة، عندما يكون المجتمع المدروس طبيعياً بمتوسط μ وانحراف معياري σ ، فإنَّه يصبح للعلاقة [9,13-a] العرض الآتي:

$$\text{var} \tilde{S}^2 = \frac{2(n-1)}{n^2} \sigma^4 \quad [9,14]$$

٢- تكون الإحصاءتان \bar{X} و \tilde{S}^2 (ومن ثمَّ \bar{X} و S^2 أيضاً) مستقلتين بعضهما عن بعض إذا وفقط إذا كان المجتمع الذي سُحبت منه العينة العشوائية \mathcal{X}_n مجتمعاً طبيعياً (انظر [24]).

(٩,٧) توزيعات المعاينة في حال مجتمع وحيد**Sampling Distributions for one Population**

لقد لاحظنا أن الإحصاءات هي متغيرات عشوائية، ومن ثم فمن أهم الأسئلة المتعلقة بها هي تلك الأسئلة التي تتعلق بمعرفة توزيعات هذه المتغيرات العشوائية. إن البحث في التوزيعات الاحتمالية للإحصاءات يُعرف باسم **توزيعات المعاينة**. في الحقيقة يمكننا أن نوجز مفهوم توزيع المعاينة على النحو الآتي:

توزيع المعاينة هو التوزيع الاحتمالي النظري الذي يبين العلاقة الدالية بين القيم الممكنة لإحصاءة مُعينة استناداً إلى عينة لـ n من الحالات والاحتمال الموافق لكل قيمة، وذلك من أجل جميع العينات الممكنة ذات الحجم n والمسحوبة من مجتمع معين، وفي هذا الصدد سنناقش حالتين من هذا الموضوع، وهما:

١- إذا كانت الدراسة تتعلق بمجتمع وحيد.

٢- إذا كانت الدراسة تتعلق بمجتمعين مستقلين.

وعلاوة على ذلك ستكون دراستنا المقبلة مركزة على المجتمعات الطبيعية والبرنولية. علماً أننا لن نخوض في تفاصيل الاستنتاجات لهذه التوزيعات، حيث سنكتفي بتقديمها، ولمن يود الاطلاع على تفاصيلها يمكنه الرجوع إلى بعض المراجع التي ذكرناها في بداية هذا الفصل.

(٩,٧,١) توزيعات المعاينة لمتوسط وتباين عينة من مجتمع طبيعي:

سنفترض على مدى هذه الفقرة أنه لدينا مجتمعاً $[\Omega, \mathcal{S}, \mathcal{P}]$ طبيعياً (أو طبيعياً على وجه التقريب) بمتوسط μ وانحراف معياري σ ، أي إن هذا المجتمع موصوف من خلال متغير عشوائي $X \sim N(\mu, \sigma)$ ، حيث نعلم أن هذين الوسيطين μ و σ هما معلمتي التوزيع الطبيعي، ولذلك عند دراسة توزيعات المعاينة لهذا المجتمع سوف ينصب الاهتمام على توزيعات المعاينة لمتوسط العينة \bar{X} وتباينها S^2 (أو انحرافها المعياري S).

(٩,٧,١,١) توزيعات المعاينة لمتوسط العينة \bar{X} :

ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً طبيعياً (أو طبيعياً على وجه التقريب) بمتوسط μ وانحراف معياري σ ، ولنأخذ $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ مع $N \ni n$ عينة مسحوبة من هذا المجتمع. عندئذ من أجل دراسة توزيع المعاينة لمتوسط العينة \bar{X}_n سنناقش الحالتين الآتيتين:

١- إذا كان تباين المجتمع معلوماً ويساوي σ_o^2 ، أي إن $\sigma_o^2 = \sigma^2$ ، فعندئذ:

أ- إذا كان حجم المجتمع غير محدود، وكان حجم العينة n كبيراً بقدر كاف، فإنه سيكون لمتوسط العينة \bar{X} توزيع طبيعي (أو طبيعي على وجه التقريب وسنفترض أنه طبيعي أيضاً)، ومن ثم بحسب المميزات العددية للمتغير العشوائي الخاضع للتوزيع الطبيعي $N(\mu, \sigma)$ ينتج لدينا:

$$\mu_{\bar{X}} = \mu \quad [9,15]$$

$$\sigma_{\bar{X}} = \frac{\sigma_o}{\sqrt{n}} \quad [9,16-a]$$

ب- إذا كان حجم المجتمع محدوداً ويساوي N ، وكان حجم العينة كبيراً نسبياً (على الأقل $0.05 N < n$)، فإنه سيكون لمتوسط العينة \bar{X} توزيع طبيعي على وجه التقريب مع $\mu_{\bar{X}} = \mu$ (كما في العلاقة [9,15]) ولكن بانحراف معياري يساوي:

$$\sigma_{\bar{X}} = \frac{\sigma_o}{\sqrt{n}} \sqrt{\frac{N-n}{N-1}} \quad [9,16-b]$$

فلاحظ هنا أنه من أجل حجم عينة n مثبت فإن:

$$\lim_{N \rightarrow \infty} \frac{\sigma_o}{\sqrt{n}} \sqrt{\frac{N-n}{N-1}} = \frac{\sigma_o}{\sqrt{n}} \lim_{N \rightarrow \infty} \sqrt{\frac{N-n}{N-1}} = \frac{\sigma_o}{\sqrt{n}}$$

ومن ثم تتوافق هذه الصيغة مع الحالة التي يكون فيها حجم المجتمع غير محدود.

٢- إذا كان تباين المجتمع الطبيعي مجهولاً (أي إن $\sigma^2 = ?$)، فإنه يُرهن أن للمتغير العشوائي $T = \frac{\bar{X} - \mu}{S / \sqrt{n}}$ توزيع ستودنت بـ $n-1$ درجة حرية، ومن ثم بحسب المميزات العددية للمتغير العشوائي الخاضع لتوزيع ستودنت ينتج لدينا أنه:

أ- إذا كان حجم المجتمع غير محدود، فإنه سيكون لـ \bar{X} متوسط $\mu_{\bar{X}} = \mu$ (كما في العلاقة [9,15])، ولكن بانحراف معياري يساوي:

$$\sigma_{\bar{X}} = \frac{s}{\sqrt{n}} \quad [9,17-a]$$

ب- إذا كان حجم المجتمع محدوداً ويساوي N (على أن يؤخذ $0.05N < n$ على الأقل)، فإنه سيكون لـ \bar{X} متوسط $\mu_{\bar{X}} = \mu$ (كما في العلاقة [9,15])، ولكن بانحراف معياري يساوي:

$$\sigma_{\bar{X}} = \frac{s}{\sqrt{n}} \sqrt{\frac{N-n}{N-1}} \quad [9,17-b]$$

وهنا يلاحظ أنه من أجل حجم عينة n مثبت سيكون لدينا:

$$\lim_{N \rightarrow \infty} \frac{s}{\sqrt{n}} \sqrt{\frac{N-n}{N-1}} = \frac{s}{\sqrt{n}}$$

وهذه الصيغة تتوافق مع الحالة التي يكون فيها حجم المجتمع غير محدود أيضاً.

(٢، ١، ٧، ٩) ملاحظة

نود أن نشير هنا إلى أن النتائج السابقة بخصوص توزيعات المعاينة لـ \bar{X} في حال مجتمع طبيعي تبقى صحيحة من أجل أي مجتمع بمتوسط μ وانحراف معياري σ أيضاً إذا كان حجم العينة كبيراً $n \geq 32$ ، وتحسن النتائج كلما تزايد حجم العينة أكثر فأكثر. أما إذا كان حجم العينة صغيراً $n > 32$ فعندئذ تصبح تلك النتائج غير مرضية إلا من أجل المجتمعات الطبيعية حيث تحافظ على جودتها.

(٣، ١، ٧، ٩) توزيعات المعاينة لتباين العينة S^2

ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً طبيعياً بمتوسط μ وانحراف معياري σ ، ولنأخذ \mathcal{X}_n عينة مسحوبة من هذا المجتمع، فعندئذ يُرهن على أنه يكون للمتغير العشوائي $\chi^2 = \frac{(n-1)S^2}{\sigma^2}$ توزيع كاي مربع بـ $n-1$ درجة حرية، ومن ثم بحسب المميزات العددية للمتغير العشوائي الخاضع لتوزيع كاي مربع ينتج أن لـ S^2 متوسط وتباين كما في العلاقتين الآتيتين على الترتيب:

$$\mu_{S^2} = \sigma^2 \quad [9,18]$$

$$\sigma_{S^2}^2 = \frac{2}{n-1} \sigma^4 \quad [9,19]$$

(٤، ١، ٧، ٩) ملاحظة

نشير هنا إلى أنه من أجل مجتمعات كيفية بمتوسط μ وانحراف معياري σ يكون للإحصاء S^2 توزيعاً احتمالياً غير بسيط (عدا حالة المجتمعات الطبيعية)، حيث يكون لمتوسط وتباين S^2 القيمة المعطاة بالعلاقة [9,12-b] و [9,13-b] على الترتيب (انظر في المبرهنة (١، ٦، ٩) والملاحظة التالية لها (٢، ٦، ٩)).

(٩, ٧, ١, ٥) مثال

لدينا آلة لإنتاج الصفائح الحديدية، فإذا علمت أن أوزان هذه الصفائح تتوزع طبيعياً على وجه التقريب بمتوسط $\mu = 500$ كغ وانحراف معياري σ ، وأتينا سحبنا عينة X_{169} من الإنتاج الكلي لهذه الآلة، فعندئذ:

١- ما هو احتمال ألا تبعد قيمة المتوسط لهذه العينة عن متوسط مجتمع الصفائح μ بأكثر من نصف كيلو غرام في كل من الحالتين الآتيتين:

أ- إذا كان $\sigma = 5$ ، ولم يذكر شيء عن حجم الإنتاج الكلي للآلة؟

ب- إذا كان $\sigma = 5$ ، وحجم الإنتاج الكلي للآلة يساوي 1000 صفيحة؟

٢- إذا افترضنا أننا لا نعلم شيء عن قيمة الانحراف المعياري لأوزان الصفائح المنتجة (أي إن $\sigma = ?$)، ووجدنا من العينة المسحوبة أن $S = 13$ كغ، فما هو احتمال ألا تزيد قيمة المتوسط لهذه العينة عن متوسط مجتمع الصفائح μ بأكثر من كيلو غرام واحد؟

٣- إذا افترضنا أن حجم العينة $n = 101$ ولدينا $\sigma = 3$ كغ، فما هو احتمال ألا تزيد قيمة التباين لهذه العينة عن قيمة التباين لمجتمع الصفائح σ^2 بأكثر من 3 كغ؟

الحل: من أجل الطلب:

أ-١- بما أنه لم يذكر شيء عن حجم الإنتاج الكلي للآلة فإننا سنفترض أن حجم المجتمع غير محدود، وبملاحظة أن حجم العينة كبير بقدر كاف فإنه سيكون لـ \bar{X} توزيع طبيعي على وجه التقريب بمتوسط $\mu_{\bar{X}} = \mu = 500$ ، وانحراف معياري:

$$\sigma_{\bar{X}} = \frac{\sigma_0}{\sqrt{n}} = \frac{5}{13} = 0.385$$

ومن ثم يكون الاحتمال المطلوب هو:

$$P(499.5 \leq \bar{X} \leq 500.5) = P\left(\frac{499.5 - \mu_{\bar{X}}}{\sigma_{\bar{X}}} \leq \frac{\bar{X} - \mu_{\bar{X}}}{\sigma_{\bar{X}}} \leq \frac{500.5 - \mu_{\bar{X}}}{\sigma_{\bar{X}}}\right) = P\left(\frac{499.5 - 500}{0.385} \leq \frac{\bar{X} - 500}{0.385} \leq \frac{500.5 - 500}{0.385}\right)$$

والآن بوضع $Z = \frac{\bar{X} - 500}{0.385}$ واستخدام جدول التوزيع الطبيعي نجد أن:

$$P(499.5 \leq \bar{X} \leq 500.5) = P(-1.30 \leq Z \leq 1.30) = P(Z \leq 1.30) - P(Z < -1.30) \\ \approx \Phi(1.30) - \Phi(-1.30) = 0.9032 - 0.0968 = 0.8064$$

ب-١- بما أن حجم الإنتاج الكلي للآلة يساوي 1000، وحجم العينة كبير بقدر كاف فإنه سيكون لـ \bar{X} توزيع طبيعي على وجه التقريب بمتوسط $\mu_{\bar{X}} = \mu = 500$ ، وانحراف معياري:

$$\sigma_{\bar{X}} = \frac{\sigma_0}{\sqrt{n}} \sqrt{\frac{N-n}{N-1}} = \frac{5}{13} \sqrt{\frac{1000-169}{999}} = 0.351$$

ومن ثم سيكون الاحتمال المطلوب هو:

$$P(499.5 \leq \bar{X} \leq 500.5) = P\left(\frac{499.5 - \mu_{\bar{X}}}{\sigma_{\bar{X}}} \leq \frac{\bar{X} - \mu_{\bar{X}}}{\sigma_{\bar{X}}} \leq \frac{500.5 - \mu_{\bar{X}}}{\sigma_{\bar{X}}}\right) \\ = P\left(\frac{499.5 - 500}{0.351} \leq \frac{\bar{X} - 500}{0.351} \leq \frac{500.5 - 500}{0.351}\right)$$

والآن بوضع $Z = \frac{\bar{X} - 500}{0.351}$ واستخدام جدول التوزيع الطبيعي نجد أن:

$$P(499.5 \leq \bar{X} \leq 500.5) = P(-1.42 \leq Z \leq 1.42) = P(Z \leq 1.42) - P(Z < -1.42) \\ \approx \Phi(1.42) - \Phi(-1.42) = 0.9222 - 0.0778 = 0.8444$$

٢- بما أننا لا نعلم شيء عن قيمة الانحراف المعياري لأوزان الصفائح المنتجة، وأنها وجدنا من العينة المسحوبة أن $S = 13$ ، وكذلك بسبب أنه لم يذكر شيء عن حجم الإنتاج الكلي للآلة فإننا سنفترض أن حجم المجتمع غير محدود، وبملاحظة أن حجم العينة كبير بقدر كاف فإنه سيكون لـ \bar{X} توزيع طبيعي على وجه التقريب بمتوسط $\mu_{\bar{X}} = \mu = 500$ ، وانحراف معياري:

$$\sigma_{\bar{X}} = \frac{S}{\sqrt{n}} = \frac{13}{\sqrt{169}} = 1$$

ومن ثم يكون الاحتمال المطلوب هو:

$$P(500 \leq \bar{X} \leq 501) = P\left(\frac{500 - \mu_{\bar{X}}}{\sigma_{\bar{X}}} \leq \frac{\bar{X} - \mu_{\bar{X}}}{\sigma_{\bar{X}}} \leq \frac{501 - \mu_{\bar{X}}}{\sigma_{\bar{X}}}\right) = P(500 - 500 \leq \bar{X} - 500 \leq 501 - 500)$$

والآن بوضع $Z = \frac{\bar{X} - \mu_{\bar{X}}}{\sigma_{\bar{X}}}$ واستخدام جدول التوزيع الطبيعي نجد أن:

$$P(500 \leq \bar{X} \leq 501) = P(0 \leq Z \leq 1) = P(Z \leq 1) - P(Z < 0) \approx \Phi(1) - \Phi(0) = 0.8413 - 0.5 = 0.3413$$

وبهذا يتم حل الطلب (٢).

٣- إن الاحتمال المطلوب هو $P(9 \leq S^2 \leq 12)$ حيث لدينا:

$$P(\sigma^2 \leq S^2 \leq \sigma^2 + 3) = P\left(\frac{(n-1)\sigma^2}{\sigma^2} \leq \frac{(n-1)S^2}{\sigma^2} \leq \frac{(n-1)(\sigma^2 + 3)}{\sigma^2}\right)$$

ولأجل حسابه يمكننا أن نكتب الآتي:

$$P(9 \leq S^2 \leq 12) = P\left(\frac{(101-1)9}{9} \leq \frac{(101-1)S^2}{9} \leq \frac{(101-1)12}{9}\right) \\ = P\left(\frac{(101-1)S^2}{9} \leq \frac{(101-1)12}{9}\right) - P\left(\frac{(101-1)S^2}{9} < \frac{(101-1)9}{9}\right)$$

وباستخدام جدول توزيع كاي مربع عند درجة الحرية 100 ينتج لدينا أن:

$$P(9 \leq S^2 \leq 12) = P\left(\frac{(101-1)S^2}{9} \leq 133.33\right) - P\left(\frac{(101-1)S^2}{9} < 100\right) \approx 0.99 - 0.90 = 0.09$$

(٢، ٧، ٩) توزيع المعاينة لمتوسط (النسبة) عينة من مجتمع برنولي

سنفترض على مدى هذه الفقرة أنه لدينا مجتمع $[\Omega, \mathcal{S}, \mathcal{P}]$ موصوف من خلال متغير عشوائي X خاضع لتوزيع برنولي بمعلمة $0 < p < 1$ (احتمال النجاح)، ولناخذ $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ عينة مسحوبة من هذا المجتمع. لقد ذكرنا في الفصل السابق أنه في حالة المجتمعات البرنولية سنستخدم الرمز $\bar{\pi}_n$ بدلاً من \bar{X}_n للتعبير عن متوسط العينة (انظر العلاقة [8-11-b])، وللأسباب التي ذكرناها سابقاً بشأن استخدام الرمز \bar{X} بدلاً من \bar{X}_n فإننا سنستخدم الرمز $\bar{\pi}$ بدلاً من $\bar{\pi}_n$ (والذي هو \bar{X}_n نفسه). عندئذ بسبب وجود معلمة واحدة لهذا المجتمع فإن الاهتمام ينصب على متوسط العينة $\bar{\pi}$ الذي يمثل التكرار النسبي للنجاحات التي

نحصل عليها من هذه العينة؛ وذلك لأن الملاحظات X_i التي يوافقها نجاحاً ستأخذ القيمة 1 ، وأما باقي الملاحظات فسوف تأخذ القيمة 0 ، أي إنه لدينا في هذه الحالة:

$$\bar{\pi} = \frac{\text{عدد النجاحات في العينة}}{\text{حجم العينة}} \quad [9,20]$$

لقد لاحظنا إن مبرهنة النهاية المركزية لموافق-لابلاس تفيدنا في هذه المسألة بأنه سيكون المتغير العشوائي $Z := \frac{\bar{\pi} - E\bar{\pi}}{\sqrt{\text{var } \bar{\pi}}}$ توزيع طبيعي معياري، ومن ثم لو رمزنا لقيمة $\bar{\pi}$ بالرمز \bar{p} فإنه سينتج لدينا الآتي:

أ- إذا كان حجم المجتمع غير محدود، وحجم العينة n كبيراً بقدر كافٍ، فإنه سيكون لـ $\bar{\pi}$ توزيع طبيعي على وجه التقريب (انظر العلاقتين [17-8]) مع:

$$\mu_{\bar{\pi}} = p \quad [9,21]$$

$$\sigma_{\bar{\pi}} = \sqrt{\frac{p(1-p)}{n}} \quad [9,22]$$

ب- إذا كان حجم المجتمع المدروس محدوداً ويساوي N ، وكان حجم العينة كبيراً نسبياً بحيث يكون $0.05N < n$ ، والسحب يتم دون إعادة، فإنه سيكون لـ $\bar{\pi}$ توزيع طبيعي على وجه التقريب بمتوسط $\mu_{\bar{\pi}} = p$ (كما في العلاقة [21,9]) ولكن بانحراف معياري:

$$\sigma_{\bar{\pi}} = \sqrt{\frac{p(1-p)}{n}} \sqrt{\frac{N-n}{N-1}} \quad [9,22]$$

وتكون هذه المقادير أكثر دقة كلما ازداد حجم العينة n أكثر فأكثر، ويلاحظ هنا كذلك أنه من أجل حجم عينة n مثبت فإن:

$$\lim_{N \rightarrow \infty} \sqrt{\frac{p(1-p)}{n}} \sqrt{\frac{N-n}{N-1}} = \sqrt{\frac{p(1-p)}{n}} \lim_{N \rightarrow \infty} \sqrt{\frac{N-n}{N-1}} = \sqrt{\frac{p(1-p)}{n}}$$

وتتوافق هذه الصيغة مع الحالة التي يكون فيها حجم المجتمع غير محدود أيضاً.

(١، ٢، ٧، ٩) ملاحظة

نشير هنا إلى أن النتائج السابقة تكون أكثر دقة عندما يكون حجم العينة كبيراً بقدر كافٍ، وتحسن النتائج أكثر فأكثر كلما ازداد حجم العينة أكثر فأكثر، وعلى أن يكون $5 \leq n \cdot p$ وكذلك $5 \leq n \cdot (1-p)$ أيضاً.

(٢، ٧، ٩) مثال

ادعى مصنع لإنتاج القطع الإلكترونية أن نسبة القطع المعيبة (غير مطابقة للمواصفات الفنية) في إنتاجه لا تتجاوز 0.05، وللتحقق من صحة هذا الادعاء أخذنا عينة من الإنتاج الكلي لهذا المصنع بحجم $n = 225$ قطعة، فوجدنا بعد فحصها أنه يوجد في هذه العينة 15 قطعة معيبة. عندئذ:

أ- لنحسب احتمال أن يكون التكرار النسبي للقطع المعيبة في إنتاج المصنع أكبر من 0.05 .

ب- لنحسب احتمال أن يكون التكرار النسبي للقطع المعيبة في إنتاج المصنع أكبر من 0.05 إذا كان مستودع الإنتاج الكلي للمصنع يحوي 10000 قطعة فقط.

الحل: من أجل الطلب:

أ- إن الاحتمال المطلوب هو $P(\bar{\pi} \geq 0.05)$ ، علماً أن الإحصاءة $\bar{\pi}$ يُعبر عن نسبة القطع المعيبة (النجاح هو الحصول على قطعة

معينة) في العينة \mathcal{X}_{225} ، وبما أنه لم يذكر شيء عن عدد القطع الموجودة في مستودع الإنتاج الكلي لهذا المصنع فإننا سنفترض في هذه الحالة أن حجم مجتمع القطع المنتجة غير محدود، ومن ثم بملاحظة أن قيمة معلمة مجتمع القطع المنتجة $p = 0.05$ فإنه سيكون لدينا:

$$P(\bar{\pi} \geq 0.05) = P\left(\frac{\bar{\pi} - 0.05}{\sqrt{(0.05)(0.95)}} \sqrt{225} \geq 0\right) = 1 - P(Z < 0) = 1 - \Phi(0) = 0.5$$

علماً أننا قد وضعنا:

$$Z = \frac{\bar{\pi} - 0.05}{\sqrt{(0.05)(0.95)}} \sqrt{225}$$

حيث سيكون $Z \sim N(0,1)$. إن هذه القيمة للاحتمال تثير لدينا الشك في أن يكون التكرار النسبي للقطع المعيبة في إنتاج هذا المصنع أكبر من 0.05 حقاً.

ب- إن الاحتمال المطلوب هو $P(\bar{\pi} \geq 0.05)$ ، ولكن في هذه الحالة حجم مجتمع القطع محدود لأنه ذكر أن مستودع الإنتاج الكلي لهذا المصنع يحوي 10000 قطعة فقط، وكذلك لدينا قيمة معلمة مجتمع القطع المنتجة $p = 0.05$ ، فعندئذ سيكون الاحتمال المطلوب يساوي:

$$\begin{aligned} P(\bar{\pi} \geq 0.05) &= P\left(\frac{\bar{\pi} - 0.05}{\sqrt{(0.05)(0.950)}} \sqrt{225} \sqrt{\frac{10000 - 225}{10000 - 1}} \geq 0\right) \\ &= 1 - P\left(\frac{\bar{\pi} - 0.05}{\sqrt{(0.05)(0.95)}} \sqrt{225} \sqrt{\frac{10000 - 225}{10000 - 1}} < 0\right) \end{aligned}$$

ومنه بوضع:

$$Z := \frac{\bar{\pi} - 0.05}{\sqrt{(0.05)(0.95)}} \sqrt{225} \sqrt{\frac{10000 - 225}{10000 - 1}}$$

سيكون $Z \sim N(0,1)$ ، ومن ثم ينتج لدينا أن:

$$P(\bar{\pi} \geq 0.05) = 1 - P(Z < 0) = 1 - \Phi(0) = 0.5$$

وهنا نجد أن قيمة الاحتمال التي حصلنا عليها تثير لدينا الشك أيضاً في أن يكون التكرار النسبي للقطع المعيبة في إنتاج هذا المصنع أكبر من 0.05 حقاً، وبذلك يتم الحل.

(٩,٨) توزيعات المعاينة لمجموعتين مستقلتين

Sampling Distributions for two Independent Populations

سنفترض على مدى هذه الفقرة أنه لدينا مجتمعين إحصائيين $[\Omega_1, \mathcal{S}_1, \mathcal{P}_1]$ و $[\Omega_2, \mathcal{S}_2, \mathcal{P}_2]$ مستقلان عن بعضهما البعض (وهذا يعني أن الجور \mathcal{S}_1 و \mathcal{S}_2 مستقلان عن بعضهما البعض)، وموصوفان من خلال متغيرين عشوائيين X و Y على الترتيب، وسنأخذ $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ و $\mathcal{Y}_m = (Y_1, Y_2, \dots, Y_m)$ عيّنتين عشوائيتين من المجتمعين $[\Omega_1, \mathcal{S}_1, \mathcal{P}_1]$ و $[\Omega_2, \mathcal{S}_2, \mathcal{P}_2]$ على الترتيب، ولنفترض أن للعينة \mathcal{X}_n متوسط \bar{X} وانحراف معياري S_X ، وكذلك للعينة \mathcal{Y}_m متوسط \bar{Y} وانحراف معياري S_Y ، علماً أن n و m عددان صحيحان موجبان مثبتان.

(٩, ٨, ١) توزيعات المعاينة لفرق متوسطي عينتين ونسبة التباين لعينتين من مجتمعين طبيعيين مستقلين

إذا كان المجتمعان $[\Omega_1, \mathcal{F}_1, \mathcal{P}_1]$ و $[\Omega_2, \mathcal{F}_2, \mathcal{P}_2]$ طبيعيين، أي إن $X \sim N(\mu_1, \sigma_1^2)$ و $Y \sim N(\mu_2, \sigma_2^2)$ ، فعندئذ ينصب

الاهتمام في هذه الحالة على دراسة توزيعات المعاينة للفرق $\bar{X} - \bar{Y}$ وللنسبة $\frac{S_X^2}{S_Y^2}$.

(٩, ٨, ١, ١) توزيعات المعاينة للفرق $\bar{X} - \bar{Y}$

تحت الفرضيات التي ذكرت آنفاً فإنه لدراسة توزيعات المعاينة للفرق $\bar{X} - \bar{Y}$ سنناقش الحالات الآتية:

١- إذا كان تباين المجتمعين σ_1^2 و σ_2^2 معلومين، أي إن $\sigma_1^2 = \sigma_{1,o}^2$ و $\sigma_2^2 = \sigma_{2,o}^2$ ، فعندئذ يكون للإحصاءة:

$$Z = \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_{1,o}^2}{n} + \frac{\sigma_{2,o}^2}{m}}}$$

توزيع طبيعي معياري، ومن ثم ينتج لدينا أن:

$$\mu_{\bar{X} - \bar{Y}} = \mu_1 - \mu_2$$

[9,23]

$$\sigma_{\bar{X} - \bar{Y}} = \sqrt{\frac{\sigma_{1,o}^2}{n} + \frac{\sigma_{2,o}^2}{m}}$$

[9,24]

٢- إذا كان تباين المجتمعين σ_1^2 و σ_2^2 مجهولين ولكنها متساويين، أي إن $\sigma_1^2 = \sigma_2^2 = \sigma^2 = ?$ ، فعندئذ يكون للمتغير العشوائي:

$$Z = \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{\sigma^2 [(1/n) + (1/m)]}}$$

توزيع طبيعي معياري، ومن ثم يكون لكل من المتغيرين العشوائيين:

$$\chi_1 = \frac{(n-1)S_X^2}{\sigma^2} \quad \& \quad \chi_2 = \frac{(m-1)S_Y^2}{\sigma^2}$$

توزيع كاي مربع بدرجات حرية $n-1$ و $m-1$ على الترتيب، ويبرهن على أن لمجموعهما $\chi_1 + \chi_2$ توزيع كاي مربع بدرجات حرية $n+m-2$ ، وبالنتيجة يمكننا أن نكتب الآتي:

$$T = \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{\sigma^2 [(1/n) + (1/m)]}} \sqrt{\frac{\sigma^2 (n+m-2)}{(n-1)S_X^2 + (m-1)S_Y^2}} = \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{(n-1)S_X^2 + (m-1)S_Y^2}} \sqrt{\frac{\sigma^2 (n+m-2)}{\sigma^2 [(1/n) + (1/m)]}}$$

ومنه يكون لدينا:

$$T = \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{(n-1)S_X^2 + (m-1)S_Y^2}} \sqrt{\frac{n+m-2}{(1/n) + (1/m)}}$$

[9,25]

فإذا أخذنا الإحصاءة:

$$S_p^2 := \frac{(n-1)S_X^2 + (m-1)S_Y^2}{n+m-2} \quad [9,26]$$

والتي تُدعى **المقدر المشترك لتباين العينتين** \mathcal{X}_n و \mathcal{Y}_m Pooled Estimator of Variance، فإنه بالتعويض في العلاقة [9,25] يبرهن على أنه سيكون للمتغير العشوائي الآتي:

$$T = \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{S_p \sqrt{(1/n) + (1/m)}}$$

توزيع ستودنت بعدد درجات حرية يساوي $n+m-2$ ، ومن ثم يكون للإحصاءة $\bar{X} - \bar{Y}$ متوسط $\mu_1 - \mu_2$ (كما في العلاقة [9,23]) ولكن بانحراف معياري يساوي:

$$\sigma_{\bar{X}-\bar{Y}} = \sqrt{\frac{(n+m)[(n-1)S_X^2 + (m-1)S_Y^2]}{n \cdot m \cdot (n+m-2)}} \quad [9,27]$$

٣- إذا كان تباين المجتمعين σ_1^2 و σ_2^2 مجهولين وغير متساويين (أي إن $\sigma_1^2 = ?$ و $\sigma_2^2 = ?$ وكذلك $\sigma_1^2 \neq \sigma_2^2$)، فعندئذ دراسة هذه الحالة ليست بسيطة وتنطوي على صعوبات، ولذلك لن نخوض في تفاصيل هذه الحالة ولن نقدم أمثلة وتمارين من أجل هذه الحالة أيضاً. لكن سيكون للمتغير العشوائي الآتي:

$$T^* = \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{(S_X^2/n) + (S_Y^2/m)}} \quad [9,28]$$

توزيع ستودنت على وجه التقريب بعدد درجات حرية يساوي:

$$df = \left\lfloor \frac{\left[(s_X^2/n) + (s_Y^2/m) \right]^2}{\sqrt{\left[\frac{1}{(n-1)}(s_X^2/n)^2 \right] + \left[\frac{1}{(m-1)}(s_Y^2/m)^2 \right]}} \right\rfloor$$

ويطلق على التقدير السابق لعدد درجات الحرية اسم **تقريب ستيرثوايت** Satterthwaite's Approximation نسبة إلى الإحصائي ستيرثوايت Satterthwaite, F. E.، وكذلك يُعرف باسم **درجات الحرية المُجمعة** pooled degrees of freedom، كما أنها تعرف باسم **معادلة ويلش-ستيرثوايت** Welch-Satterthwaite equation، وقد نشره في عمل عام 1946، علماً أن $\lceil x \rceil$ هو أصغر عدد صحيح أكبر من x .

(٢، ١، ٨، ٩) ملاحظات

نود أن نشير هنا إلى أنه من أجل مجتمعين غير طبيعيين $[\Omega_1, \mathcal{S}_1, \mathcal{P}_1]$ بمتوسط μ_1 وانحراف معياري σ_1 وكذلك $[\Omega_2, \mathcal{S}_2, \mathcal{P}_2]$ بمتوسط μ_2 وانحراف معياري σ_2 تبقى النتائج السابقة بخصوص توزيعات المعاينة للفرق $\bar{X} - \bar{Y}$ صحيحة إذا كان حجم كل من العينتين \mathcal{X}_n و \mathcal{Y}_m كبيراً بقدر كاف، وتحسن النتائج كلما ازداد حجم أي من العينتين أكثر فأكثر. أما إذا كان حجم أي من العينتين \mathcal{X}_n و \mathcal{Y}_m صغيراً فإن تلك النتائج ستصبح غير مرضية إلا من أجل المجتمعات الطبيعية حيث تحافظ على جودتها.

(٩, ٨, ١, ٣) توزيع المعاينة للنسبة $\frac{S_X^2}{S_Y^2}$:

تحت الفرضيات المقدمة سابقاً في (٩-٨-١) يبرهن على أنه سيكون للمتغير العشوائي الآتي:

$$F := \frac{S_X^2 \cdot \sigma_2^2}{S_Y^2 \cdot \sigma_1^2} \quad [9,29]$$

توزيع فيشر بـ $m-1$ درجة حرية بسط و $n-1$ درجة حرية مقام. أي إن $F \sim F(m-1, n-1)$ ، ومن ثم بحسب المميزات العددية لمتغير عشوائي خاضع لتوزيع فيشر ذي $m-1$ درجة حرية بسط و $n-1$ درجة حرية مقام سيكون للإحصاءة $\frac{S_X^2}{S_Y^2}$ متوسط وتباين كما في العلاقتين الآتيتين على الترتيب:

$$\mu_{\frac{S_X^2}{S_Y^2}} = \frac{(n-1) \sigma_1^2}{(n-3) \sigma_2^2} \quad ; n \geq 4 \quad [9,30]$$

$$\sigma_{\frac{S_X^2}{S_Y^2}}^2 = \frac{2(n-1)^2 (m+n-4) \sigma_1^4}{(m-1)(n-3)^2 (n-5) \sigma_2^4} \quad ; m \geq 2, n \geq 6 \quad [9,31]$$

نلاحظ هنا أنه إذا كان تباين المجتمعين متساويين (أي إن $\sigma_1^2 = \sigma_2^2 = \sigma^2$) فعندئذ يبرهن على أنه سيكون للإحصاءة $F := \frac{S_X^2}{S_Y^2}$ توزيع فيشر ذو الـ $m-1$ درجة حرية و $n-1$ درجة حرية ولكن بمتوسط وتباين كما في العلاقتين الآتيتين على الترتيب:

$$\mu_{\frac{S_X^2}{S_Y^2}} = \frac{(n-1)}{(n-3)} \quad ; n \geq 4 \quad [9,32]$$

$$\sigma_{\frac{S_X^2}{S_Y^2}}^2 = \frac{2(n-1)^2 (m+n-4)}{(m-1)(n-3)^2 (n-5)} \quad ; m \geq 2, n \geq 6 \quad [9,33]$$

(٩, ٨, ١, ٤) مثال

في متجرين A و B مستقلين عن بعضهما يوجد نوع من الملابس بقياسات ونماذج (موديلات) مختلفة، وقد أفادنا أصحاب هذين المتجرين أن متوسط أسعار القطع في المتجر الأول A يساوي 53 وحدة نقدية بانحراف معياري قدره 3 وحدات نقدية بينما متوسط أسعار القطع في المتجر الثاني B يساوي 55 وحدة نقدية بانحراف معياري قدره وحدتين نقديتين. قمنا بسحب عينة من ملابس المتجر A بحجم 25 قطعة فوجدنا أن متوسط أسعار قطع هذه العينة يساوي 52 وحدة نقدية بانحراف معياري قدره 4 وحدات نقدية، وكذلك قمنا بسحب عينة أخرى من ملابس المتجر B بحجم 36 قطعة فوجدنا أن متوسط أسعار قطع هذه العينة يساوي 54 وحدة نقدية بانحراف معياري قدره 3 وحدات نقدية، فإذا علمنا أن أسعار القطع تتوزع طبيعياً على وجه التقريب، فعندئذ:

أ- لنحسب احتمال أن يكون الفرق بين متوسطي العينتين لا يتجاوز وحدتين نقديتين.

ب- لنحسب احتمال أن تكون نسبة تباين العينة الثانية إلى تباين العينة الأولى أصغر من الواحد.

الحل: بما أنه لم يُحدد حجم المجتمع فسوف نفترض أن حجم هذا المجتمع غير محدود، ومن ثم يكون من أجل الطلب:

أ- لدينا من معطيات المسألة التباين لكل من المجتمعين معلوماً، ومن ثم يمكننا أن نكتب الآتي:

$$P(|\bar{X} - \bar{Y}| \leq 2) = P(-2 \leq \bar{X} - \bar{Y} \leq 2) = P(\bar{X} - \bar{Y} \leq 2) - P(\bar{X} - \bar{Y} < -2)$$

ولكن لدينا:

$$\begin{aligned}
 P(\bar{X} - \bar{Y} \leq 2) &= P\left(\frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}}} \leq \frac{2 - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}}}\right) \\
 &= P\left(\frac{(\bar{X} - \bar{Y}) - (50 - 53)}{\sqrt{\frac{9}{25} + \frac{4}{36}}} \leq \frac{2 - (50 - 53)}{\sqrt{\frac{9}{25} + \frac{4}{36}}}\right) \\
 &= P\left(\frac{(\bar{X} - \bar{Y}) - (50 - 53)}{\sqrt{\frac{9}{25} + \frac{4}{36}}} \leq 7.28\right) = P(Z \leq 7.28) = \Phi(7.28) \approx 1
 \end{aligned}$$

وكذلك لدينا:

$$\begin{aligned}
 P(\bar{X} - \bar{Y} < -2) &= P\left(\frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}}} < \frac{-2 - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}}}\right) \\
 &= P\left(\frac{(\bar{X} - \bar{Y}) - (50 - 53)}{\sqrt{\frac{9}{25} + \frac{4}{36}}} < \frac{-2 - (50 - 53)}{\sqrt{\frac{9}{25} + \frac{4}{36}}}\right) \\
 &= P\left(\frac{(\bar{X} - \bar{Y}) - (50 - 53)}{\sqrt{\frac{9}{25} + \frac{4}{36}}} < -1.46\right) = \Phi(-1.46) = 0.075
 \end{aligned}$$

وذلك لأن $Z := \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}}} \sim N(0, 1)$ ، ومن ثم ينتج لدينا أن الاحتمال المطلوب هو:

$$P(|\bar{X} - \bar{Y}| \leq 2) \approx 1 - 0.075 = 0.925$$

٢- إن الاحتمال المطلوب هو:

$$P\left(\frac{S_Y^2}{S_X^2} < 1\right) = P\left(\frac{S_Y^2 \sigma_1^2}{S_X^2 \sigma_2^2} < \frac{\sigma_1^2}{\sigma_2^2}\right) = P\left(F < \frac{9}{4}\right) = P(F < 2.25)$$

حيث وضعنا $F := \frac{9S_Y^2}{4S_X^2}$ الذي له توزيع فيشر $F(24, 35)$ ، ولذلك نجد من جدول توزيع فيشر أن:

$$P\left(\frac{S_Y^2}{S_X^2} < 1\right) = P(F < 2.25) \approx 0.975$$

وذلك أنه لدينا أقرب قيمة لـ 2.25 هي 2.14 التي تقابل القيمة المقابلة لـ $m = 24$ و $n = 30$ حيث لدينا $f_{0.975}^{(24; 30)} = 2.14$.

(٢, ٨, ٩) توزيعات المعاينة للفرق بين متوسطي (نسبتي) عينتين من مجتمعين برنوليين مستقلين

إذا كان المجتمعان $[\Omega_1, \mathcal{S}_1, \mathcal{P}_1]$ و $[\Omega_2, \mathcal{S}_2, \mathcal{P}_2]$ برنوليين، أي إن $X \sim B(p_1)$ و $Y \sim B(p_2)$ ، فعندئذ ينصبّ الاهتمام في هذه الحالة على دراسة توزيعات المعاينة للفرق $\bar{\pi}_1 - \bar{\pi}_2$ ، علماً أن $\bar{\pi}_1$ و $\bar{\pi}_2$ هو التكرار النسبي للنجاحات في العينة \mathcal{X}_n و \mathcal{Y}_m على الترتيب. الآن، وتحت الفرضيات المذكورة آنفاً يبرهن على أنه سيكون للإحصاءة:

$$W = \frac{(\bar{\pi}_1 - \bar{\pi}_2) - (p_1 - p_2)}{\sqrt{\frac{m[p_1(1-p_1)] + n[p_2(1-p_2)]}{n \cdot m}}} \quad [9,34]$$

توزيع طبيعي معياري بمتوسط وانحراف معياري على الترتيب هما:

$$\mu_{\bar{\pi}_1 - \bar{\pi}_2} = p_1 - p_2 \quad [9,35]$$

$$\sigma_{\bar{\pi}_1 - \bar{\pi}_2} = \sqrt{\frac{m[p_1(1-p_1)] + n[p_2(1-p_2)]}{n \cdot m}} \quad [9,36]$$

لدى التطبيق يستعاض عن p_1 و p_2 بالقيم \bar{p}_1 و \bar{p}_2 على الترتيب لأننا ننتقل من أن قيم معالم المجتمع مجهولة كلياً أو جزئياً على الأقل، وذلك لأنه لو كانت معالم المجتمع معلومة لما كان هناك حاجة لهذه الدراسة من أجل جمع المعلومات حول المعالم.

(١, ٢, ٨, ٩) مثال

يود أحد تجار الجملة استيراد نوع من الأطعمة المعلّبة (الكنسروة) من إحدى شركتين تعمل كلّ منهما بشكل مستقل عن الأخرى، حيث ادعت الشركة الأولى A أن نسبة المعيب في إنتاجها منخفض جداً مقارنةً مع بقية الشركات المصنّعة لهذا المنتج، بينما ادعت الشركة الثانية B أن نسبة المعيب في إنتاجها منخفض جداً مقارنةً مع بقية الشركات المصنّعة لهذا المنتج أيضاً. قام التاجر بأخذ عينة بحجم $n = 144$ علبة من إنتاج الشركة A وتم اختبارها فوجد 5 علب معيبة، ثم أخذ عينة أخرى من إنتاج الشركة B بحجم $m = 100$ وتم اختبارها فوجد 4 علب معيبة.

الآن، قرر هذا التاجر بأنه لن يفاضل بين هاتين الشركتين (لن يُفضّل إحداها على الأخرى) إذا كان الفرق بين نسب العلب المعيبة لإنتاج الشركتين أكبر من 0.01 باحتمال أصغر من الـ 0.5، فإذا علمت أن التوزيع الاحتمالي لجودة المنتج له توزيع طبيعي على وجه التقريب، فهل سيضطر التاجر إلى المفاضلة بين هاتين الشركتين، وفي حال المفاضلة أي الشركتين سيختار؟

الحل: نلاحظ أن إنتاج الشركتين يمكن تمثيله بمجتمعين $[\Omega_1, \mathcal{S}_1, \mathcal{P}_1]$ و $[\Omega_2, \mathcal{S}_2, \mathcal{P}_2]$ برنوليين بمعلمة p_1 و p_2 على الترتيب، وسنفترض أن عدد العلب المنتجة من قبل الشركتين كبير جداً (لأنه لم يذكر شيء حول حجم الإنتاج لهما). عندئذ سيكون للإحصاءة $\bar{\pi}_1 - \bar{\pi}_2$ توزيع طبيعي معياري (وفقاً لمبرهنة موافير-لابلاس) بمتوسط وانحراف معياري على الترتيب هما:

$$\mu_{\bar{\pi}_1 - \bar{\pi}_2} = p_1 - p_2$$

$$\sigma_{\bar{\pi}_1 - \bar{\pi}_2} = \sqrt{\frac{m[p_1(1-p_1)] + n[p_2(1-p_2)]}{n \cdot m}}$$

وبما أن p_1 و p_2 مجهولتان فإنه يستعاض عنهما بـ $\bar{p}_1 = \frac{5}{144} = 0.0347$ و $\bar{p}_2 = \frac{4}{100} = 0.04$ على الترتيب، ومن ثم يصبح لدينا:

$$\mu_{\bar{\pi}_1 - \bar{\pi}_2} = \bar{p}_1 - \bar{p}_2 = 0.0347 - 0.04 = -0.0053$$

$$\sigma_{\bar{\pi}_1 - \bar{\pi}_2} = \sqrt{\frac{m[\bar{p}_1(1-\bar{p}_1)] + n[\bar{p}_2(1-\bar{p}_2)]}{n \cdot m}} = 0.0249$$

وعندئذ يتوقف قرار التاجر على معرفة قيمة الاحتمال $P(|\bar{\pi}_1 - \bar{\pi}_2| \geq 0.01)$ ، حيث لدينا:

$$\begin{aligned} P(|\bar{\pi}_1 - \bar{\pi}_2| \geq 0.01) &= 1 - P(|\bar{\pi}_1 - \bar{\pi}_2| < 0.01) = 1 - P(-0.01 < \bar{\pi}_1 - \bar{\pi}_2 < 0.01) \\ &= 1 - P\left(\frac{-0.01 - \mu_{\bar{\pi}_1 - \bar{\pi}_2}}{\sigma_{\bar{\pi}_1 - \bar{\pi}_2}} < \frac{(\bar{\pi}_1 - \bar{\pi}_2) - \mu_{\bar{\pi}_1 - \bar{\pi}_2}}{\sigma_{\bar{\pi}_1 - \bar{\pi}_2}} < \frac{0.01 - \mu_{\bar{\pi}_1 - \bar{\pi}_2}}{\sigma_{\bar{\pi}_1 - \bar{\pi}_2}}\right) \\ &= 1 - P\left(\frac{-0.01 + 0.0053}{0.0249} < \frac{(\bar{\pi}_1 - \bar{\pi}_2) + 0.0053}{0.0249} < \frac{0.01 + 0.0053}{0.0249}\right) \\ &\text{وبوضع } Z = \frac{(\bar{\pi}_1 - \bar{\pi}_2) + 0.0053}{0.0249} \text{ يصبح لدينا:} \end{aligned}$$

$$\begin{aligned} P(|\bar{\pi}_1 - \bar{\pi}_2| \geq 0.01) &= 1 - P(0.61 < Z < -0.19) = 1 - [\Phi(0.61) - \Phi(-0.19)] \\ &= 1 - (0.7291 - 0.4247) = 1 - 0.3044 = 0.6956 \end{aligned}$$

إذا سيضطر التاجر إلى المفاضلة بين هاتين الشركتين، ويكون في هذه الحالة اختيار الشركة A هو الأفضل لأن نسب العلب المعيبة لديها (بحسب نتيجة العينة) هو الأقل.

بعد هذا التقديم الموجز لبعض توزيعات المعاينة سنقدم إحدى الصفات المهمة التي يمكن لإحصاءة ما التمتع بها. إن هذه الصفة تُعرف باسم **صفة الكفاية للإحصاءة**.

(٩، ٩) الإحصاءة الكافية

Sufficiency Statistic

ليكن لدينا $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X دالة كثافته الاحتمالية $f_X(x; \theta)$ ، ولنأخذ $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ عينة من هذا المجتمع، ولنفترض أن X هي الساحة التي تتحول عليها قيم المتجه \mathcal{X}_n . الآن لنأخذ الإحصاءات الآتية:

$$\left. \begin{aligned} T_1 &= u_1(\mathcal{X}_n) \\ T_2 &= u_2(\mathcal{X}_n) \\ &\vdots \\ T_n &= u_n(\mathcal{X}_n) \end{aligned} \right\} \quad [9,37]$$

وسنفترض أن للمتجه $T_n = (T_1, T_2, \dots, T_n)$ دالة كثافة احتمالية $g(\vec{t}_n; \theta)$ ، وأن الساحة التي تتحول عليها قيم هذا المتجه هي \mathbf{T} ، فإذا كان لجملة المعادلات [9,37] حل وحيد من الشكل:

$$\left. \begin{aligned} x_1 &= w_1(\vec{t}_n; \theta) \\ x_2 &= w_2(\vec{t}_n; \theta) \\ &\vdots \\ x_n &= w_n(\vec{t}_n; \theta) \end{aligned} \right\} \quad [9,38]$$

وكان الشرطان الآتيان مُحققين أيضاً:

- أ- يوجد تقابل واحد لواحد بين قيم \mathcal{X}_n في الساحة X وقيم T_n في الساحة T .
- ب- من أجل كل $N_n \ni k$ لدينا الدوال w_k مستمرة وتملك مشتقات جزئية أولى مستمرة في كل من t_1, t_2, \dots, t_n و $T \ni t_n$. فعندئذ ستكون العلاقة الآتية مُحَقَّقة:

$$g(\vec{t}_n; \theta) = |J| f_{\mathcal{X}_n}(w_1(\vec{t}_n; \theta), w_2(\vec{t}_n; \theta), \dots, w_n(\vec{t}_n; \theta)) = |J| \cdot \prod_{k=1}^n f_{X_k}(w_k(\vec{t}_n; \theta)) \quad [9,39]$$

علماً أنَّ $\vec{t} := (t_1, t_2, \dots, t_n)$ ، وأما J فهي قيمة المعين اليعقوبي Jacobean Determinant، وتحسب بالعلاقة الآتية:

$$J \triangleq \frac{\partial(x_1, x_2, \dots, x_n)}{\partial(t_1, t_2, \dots, t_n)} = \begin{vmatrix} \frac{\partial x_1}{\partial t_1} & \frac{\partial x_1}{\partial t_2} & \dots & \frac{\partial x_1}{\partial t_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial x_n}{\partial t_1} & \frac{\partial x_n}{\partial t_2} & \dots & \frac{\partial x_n}{\partial t_n} \end{vmatrix} \quad [9,40]$$

ومن العلاقة [9,39] يمكننا حساب دالة الكثافة الاحتمالية لأية إحصاءة T_k مع $N_n \ni k$ باستخدام التوزيعات الهامشية، ومن ثم بفرض $g_k(t_k; \theta)$ هي دالة الكثافة الهامشية لـ T_k لكل $N_n \ni k$ ، فإن:

$$h(t_2, t_3, \dots, t_n; \theta | t_1) := \begin{cases} \frac{g(\vec{t}_n; \theta)}{g_1(t_1; \theta)} & \text{for } g_1(t_1; \theta) > 0 \\ 0 & \text{for } g_1(t_1; \theta) = 0 \end{cases} \quad [9,41]$$

هي دالة الكثافة الشرطية للمتجه T_n عندما يكون $T_1 = t_1$ مُحَقَّقاً، فإذا كانت الدالة h غير متعلقة بالمعلمة θ مهما تكن الإحصاءات T_2, T_3, \dots, T_n ، فعندئذ تكون T_1 إحصاءة كافية للمعلمة θ .

إنَّ المعنى الاحتمالي لما سبق هو أنَّ أية إحصاءة أخرى غير T_1 لن تُقدِّم معلومات إضافية حول θ بأكثر مما قدَّمته الإحصاءة T_1 .

(٩, ٩, ١) تعريف (الإحصاءة الكافية Sufficient Statistic)

تحت الفرضيات المذكورة آنفاً في بداية هذه الفقرة ليكن $T = g(\mathcal{X}_n)$ إحصاءة مُعطاة، فعندئذ يُقال عن T إنها إحصاءة كافية للمعلمة θ إذا كانت أية إحصاءة أخرى $U = h(\mathcal{X}_n)$ لا تُقدِّم معلومات إضافية حول المعلمة θ بأكثر مما قدَّمته الإحصاءة T .

تجدر الإشارة هنا إلى أنَّ الإحصاءة الكافية لمعلمة θ ليست وحيدة في الحالة العامة، وكذلك التعامل مع تعريف الإحصاءة الكافية لتبيان إن كانت إحصاءة ما T هي إحصاءة كافية لمعلمة المجتمع أم لا، هو أمر شاق في معظم الحالات، فلذلك تُقدِّم اختبارات سهلة التطبيق (بالمقارنة مع تطبيق التعريف) للحكم على إحصاءة ما إن كانت كافية لمعلمة المجتمع أم لا.

إنَّ مبرهنة فيشر – نويمان الآتية (التي سنقبلها دون برهان) تُعدُّ أحد الاختبارات المستخدمة في إثبات إن كانت إحصاءة T كافية لمعلمة المجتمع أم لا.

(٩, ٩, ٢) مبرهنة (فيشر – نويمان Fisher-Neumann Proposition)

تحت الفرضيات التي ذكرت في بداية الفقرة (٩, ٩)، وبفرض أنَّ $T_k = u_k(\mathcal{X}_n)$ مع $N_n \ni k$ إحصاءات مُعطاة، فعندئذ تكون الإحصاءة T_1 كافية للمعلمة θ (وبالمثل ينطبق القول على أي من الإحصاءات الأخرى) إذا وفقط إذا كان ما يلي مُحَقَّقاً:

$$f_{\mathcal{X}_n}(\vec{x}_n; \theta) = w_1(u_1(\vec{x}_n); \theta) \cdot h(\vec{x}_n) \quad [9,42]$$

علماً أنَّ $w_1(u_1(\vec{x}_n); \theta)$ هي دالة الكثافة الاحتمالية للإحصاءة T_1 ، وأما $h(\vec{x}_n)$ فهي دالة مستقلة عن θ من أجل أية قيمة $t_1 = u_1(\vec{x}_n)$ للإحصاءة T_1 .

تقدم لنا المبرهنة الآتية (التي سنقبلها دون برهان أيضاً) اختباراً آخر لتبيان إن كانت إحصاءة ما T كافية لمعلمة المجتمع θ أم لا.

(٩, ٩, ٣) مبرهنة (التحليل إلى عوامل Analysis to Factors)

تحت الفرضيات المذكورة في بداية الفقرة (٩, ٩)، وبفرض أن $T_k = u_k(X_n)$ مع $N_n \ni k$ إحصاءات معطاة، فعندئذ تكون الإحصاءة T_1 كافية للمعلمة θ إذا وفقط إذا أمكننا أن نكتب ما يلي:

$$\prod_{k=1}^n f_{X_k}(x_k; \theta) = \tilde{g}(u(\vec{x}_n); \theta) \cdot \tilde{h}(\vec{x}_n) \quad [9,43]$$

علماً أن \tilde{h} دالة مستقلة عن θ و \tilde{g} دالة متعلقة بالمعلمة θ في الحالة العامة.

(٩, ٩, ٣, ١) أمثلة

١- ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً برنولياً معلمته $0 < p < 1$ ، ولناخذ $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ عينة من هذا المجتمع، ولتكن T إحصاءة تمثل مجموع النجاحات في هذه العينة، أي إن $T = u(\mathcal{X}_n) = \sum_{k=1}^n X_k$ ، ولنبين إن كانت هذه الإحصاءة كافية للمعلمة p أم لا.

الحل: نعلم أن:

$$f_X(x; p) = p^x (1-p)^{1-x} \quad ; x \in \{0, 1\}$$

ومن ثم يكون لدينا:

$$\prod_{k=1}^n f_{X_k}(x_k; p) = p^{\sum_{k=1}^n x_k} (1-p)^{n - \sum_{k=1}^n x_k} \quad (1)$$

ولكن نعلم أنه إذا كانت X_1, X_2, \dots, X_n متغيرات عشوائية برنولية مستقلة، فإن مجموعها سيخضع للتوزيع الحداني بمعلمتين n و p ، ومن ثم بوضع $t = \sum_{i=1}^n x_i$ فإنه سيكون لدالة الكثافة الاحتمالية للإحصاءة T العرض الآتي:

$$w_T(t; p) = \binom{n}{t} p^t (1-p)^{n-t} \quad (2)$$

وبسبب تحقق العلاقتين (1) و (2) أن نكتب الآتي:

$$\prod_{k=1}^n f_{X_k}(x_k; p) = \binom{n}{\sum_{k=1}^n x_k} p^{\sum_{k=1}^n x_k} (1-p)^{n - \sum_{k=1}^n x_k} \left(\binom{n}{\sum_{k=1}^n x_k} \right)^{-1}$$

ومنه بوضع:

$$h(\vec{x}_n) = \left(\binom{n}{\sum_{k=1}^n x_k} \right)^{-1} \quad \& \quad w_T(u(\vec{x}_n); p) = \binom{n}{\sum_{k=1}^n x_k} p^{\sum_{k=1}^n x_k} (1-p)^{n - \sum_{k=1}^n x_k}$$

تنتج لدينا العلاقة الآتية:

$$\prod_{k=1}^n f_{X_k}(x_k; p) = w_T(u(\vec{x}_n); p) \cdot h(\vec{x}_n)$$

ومنه بحسب اختبار فيشر-نويمان تكون T إحصاءة كافية للمعلمة p .

٢- ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X خاضع للتوزيع الطبيعي $N(\mu, \sigma)$ علماً أن σ معلومة، ولنأخذ $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ عينة من هذا المجتمع، ولنبين فيما إذا كانت الإحصاءة \bar{X} كافية لمتوسط المجتمع μ أم لا.

الحل: من أجل ذلك لدينا:

$$\begin{aligned} f_{\mathcal{X}_n}(\bar{x}_n; \mu) &= \prod_{k=1}^n f_{X_k}(x_k; \mu) = \left(\frac{1}{2\pi\sigma^2} \right)^{\frac{n}{2}} \exp \left[-\frac{1}{2\sigma^2} \sum_{k=1}^n (x_k - \mu)^2 \right] \\ &= \left(\frac{1}{2\pi\sigma^2} \right)^{\frac{n}{2}} \exp \left[-\frac{n(\bar{x} - \mu)^2 + \sum_{k=1}^n (x_k - \bar{x})^2}{2\sigma^2} \right] \end{aligned}$$

ولكن من المعلوم أن للإحصاء \bar{X} توزيع $N\left(\mu, \frac{\sigma}{\sqrt{n}}\right)$ ، ومن ثم يكون لدالة كثافته الاحتمالية العرض الآتي:

$$g_{\bar{X}}(u(\bar{x}_n); \mu) = \left(\frac{\sqrt{n}}{\sigma\sqrt{2\pi}} \right) \exp \left[-\frac{1}{2\sigma^2} n(\bar{x} - \mu)^2 \right]$$

وبوضع:

$$\begin{aligned} \tilde{h}(\bar{x}_n) &:= \frac{1}{\sqrt{n}} \left(\frac{1}{2\pi\sigma^2} \right)^{\frac{n-1}{2}} \exp \left[-\frac{1}{2\sigma^2} \sum_{k=1}^n (x_k - \bar{x})^2 \right] \\ g_{\bar{X}}(u(\bar{x}_n); \mu) &= \left(\frac{n}{2\pi\sigma^2} \right)^{\frac{1}{2}} \exp \left[-\frac{n(\bar{x} - \mu)^2}{2\sigma^2} \right] \end{aligned}$$

ف نجد أن $\tilde{h}(\bar{x}_n)$ مستقلة عن المعلمة μ ، وكذلك لدينا:

$$f_{\mathcal{X}_n}(\bar{x}_n; \mu) = g_{\bar{X}}(u(\bar{x}_n); \mu) \cdot \tilde{h}(\bar{x}_n)$$

وهذا يعني بحسب اختبار فيشر-نويان أن الإحصاءة \bar{X} هي إحصاءة كافية للمعلمة μ .

تؤكد لنا المبرهنة الآتية (التي سنقبلها دون برهان أيضاً) أن الإحصاءة الكافية للمعلمة مجتمع ليست وحيدة في الحالة العامة.

(٩, ٩, ٤) مبرهنة

ليكن $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X دالة كثافته الاحتمالية $f_X(x; \theta)$ ، ولنأخذ \mathcal{X}_n عينة من هذا المجتمع، ولنفترض أن $T = g(\mathcal{X}_n)$ إحصاءة كافية للمعلمة θ ، وليكن $S = g(T)$ مع g دالة تقابل، فعندئذ ستكون S إحصاءة كافية للمعلمة θ أيضاً.

(٩, ٩, ٥) أمثلة

١- لقد بينا في المثال ١ / من (٩, ٩, ٣, ١) أن الإحصاءة التي تمثل مجموع النجاحات في عينة \mathcal{X}_n من مجتمع برنولي معلمته p هي إحصاءة كافية لهذه المعلمة، ومن ثم بحسب المبرهنة السابقة (٩, ٩, ٤) تكون الإحصاءة $\bar{\pi}$ التي تمثل التكرار النسبي للنجاحات في العينة \mathcal{X}_n هي إحصاءة كافية للمعلمة p أيضاً.

٢. لقد بينا في المثال / ٢ / من (٩, ٩, ٣, ١) أن \bar{X} هي إحصاء كافية لاهتوسط مجتمع طبيعي عُدَّ تم تباينه، ومن ثم بحسب المبرهنة السابقة (٩, ٩, ٤) ستكون الإحصاءة $a\bar{X} + b$ هي إحصاء كافية لـ μ أيضاً من أجل أية قيم $a, b \in \mathbb{R}$ مع $a \neq 0$.

(٩, ١٠) كمية معلومات فيشر التي تقدمها عينة عشوائية

Fisher's Information Quantity Provided by a Random Sample

سنقدم فيما يلي كمية معلومات فيشر التي يقدمها عنصر من عينة، ومن ثم الانتقال إلى كمية معلومات فيشر التي تقدمها عينة بحجم n . لكن تقديم هذا المفهوم يتطلب التعرف على بعض المفاهيم الأخرى التي سوزدها تبعاً.

(٩, ١٠, ١) تعريف (المتغير العشوائي النظامي Regular Random variables):

ليكن لدينا $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X دالة كثافته الاحتمالية $f_X(x; \theta)$ ، ولناخذ $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ عينة من هذا المجتمع، فإذا كان من أجل كل $\theta \in \Theta$ لدينا البندين الآتين محققين:

أ- القيم $E \left(\frac{\partial \ln f_X(x; \theta)}{\partial \theta} \right)$ موجودة.

ب- لدينا: $\frac{\partial}{\partial \theta} \int_{-\infty}^{\infty} f_X(x; \theta) dx = 0$ for X continuous

$\frac{\partial}{\partial \theta} \sum_{i \in I} f_X(x_i; \theta) = 0$ for X discrete

فعندئذ يُقال عن X إنه متغير عشوائي نظامي في المجموعة Θ .

(٩, ١٠, ١, ١) مثال

ليكن لدينا $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X خاضع للتوزيع الأسّي بمعلمة $\lambda > 0$ ، فعندئذ نجد أن هذا المتغير العشوائي نظامي في فترة $(0, \infty) \supseteq (0, b)$ وذلك لأنه بفرض \mathcal{X}_n عينة مسحوبة من هذا المجتمع، فإنه سيكون لدينا:

$$\begin{aligned} E \left| \frac{\partial \ln f(x; \lambda)}{\partial \lambda} \right| &= \int_{-\infty}^{\infty} \left| \frac{\partial \ln f_X(x; \lambda)}{\partial \lambda} \right| f_X(x; \lambda) dx \\ &= \int_{-\infty}^{\infty} \left| \frac{1}{\lambda} - x \right| \lambda e^{-\lambda x} \mathbf{I}_{(0, \infty)}(x) dx = \int_0^{\infty} \left(\frac{1}{\lambda} - x \right) \lambda e^{-\lambda x} dx \\ &= \int_0^{\infty} e^{-\lambda x} dx - \int_0^{\infty} \lambda x e^{-\lambda x} dx = \frac{1}{\lambda} - \frac{1}{\lambda} = 0 \end{aligned}$$

وهذا يعني أن $E \left(\frac{\partial \ln f_X(x; \lambda)}{\partial \lambda} \right) = 0$ موجودة.

وكذلك نجد:

$$\frac{\partial}{\partial \lambda} \int_{-\infty}^{\infty} f_X(x; \theta) dx = \frac{\partial}{\partial \lambda} \int_0^{\infty} \lambda e^{-\lambda x} dx = 0$$

وهذا يعني أن المتغير العشوائي X نظامي.

(٩, ١٠, ١, ٢) ملاحظات

- ١- إذا كان X متغيراً عشوائياً نظامياً، فعندئذ يُقال عن دالة توزيعه إنها دالة توزيع نظامية.
- ٢- إذا كان X متغيراً عشوائياً نظامياً، وكان $T = g(\mathcal{X}_n)$ إحصاءة كافية لـ θ ، فإنه يبرهن على أن T نظامية أيضاً.
- ٣- إن العينة العشوائية المولدة من متغير عشوائي نظامي تدعى **عينة عشوائية نظامية**.

(٩, ١٠, ٢) كمية معلومات فيشر التي يقدمها عنصر من عينة

Fisher's Information Quantity Provided by an Element of a Sample

ليكن $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X دالة كثافته الاحتمالية $f_X(x; \theta)$ ، ولناخذ \mathcal{X}_n عينة من هذا المجتمع. إن **كمية معلومات فيشر** التي يقدمها عنصر من هذه العينة حول المعلمة θ سنرمز لها بـ $I(\theta)$ ، وتعرف من خلال العلاقة الآتية:

$$I(\theta) = E \left(\frac{-\partial^2 \ln f_X(x; \theta)}{\partial \theta^2} \right) \quad [9,44]$$

(٩, ١٠, ٢, ١) ملاحظات

١- يمكن إثبات أن:

$$I(\theta) = E \left(\frac{-\partial^2 \ln f_X(x; \theta)}{\partial \theta^2} \right) = E \left(\frac{\partial \ln f_X(x; \theta)}{\partial \theta} \right)^2 \geq 0 \quad [9,45]$$

أي إن كمية المعلومات التي يقدمها عنصر من عينة حول المعلمة θ هي مقدار غير سالب.

٢- إذا كان $I(\theta) = 0$ فإن ذلك يعني أن $f_X(x; \theta)$ مستقلة عن θ ، وهذا يعني بدوره أن المتغير العشوائي X لا يقدم أية معلومات حول المعلمة θ ، ومن ثم يمكن إثبات أن دالة الكثافة $f_X(x; \theta)$ ثابتة باحتمال يساوي الواحد (بالنسبة إلى القياس P_θ).

٣- سنرمز لكمية المعلومات التي تقدمها إحصاءة $T = g(\mathcal{X}_n)$ حول معلمة θ بالرمز $I_T(\theta)$.

تبين لنا المبرهنة الآتية أن كمية المعلومات التي تقدمها عينة تساوي كمية المعلومات التي يقدمها عنصر من هذه العينة مضروباً بحجم هذه العينة.

(٩, ١٠, ٢, ٢) مبرهنة

ليكن لدينا $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X دالة كثافته الاحتمالية $f_X(x; \theta)$ ، ولناخذ \mathcal{X}_n عينة من هذا المجتمع، وبفرض أن $I_{\mathcal{X}_n}(\theta)$ هي كمية المعلومات التي تقدمها العينة العشوائية \mathcal{X}_n ، فعندئذ ستكون العلاقة الآتية مُحَقَّقة:

$$I_{\mathcal{X}_n}(\theta) = n \cdot I(\theta) \quad [9,46]$$

البرهان: بسبب الاستقلال والتطابق في التوزيع للملاحظات العينة X_1, X_2, \dots, X_n يمكننا أن نكتب من أجل أي

$$\vec{x}_n = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n \text{ ما يلي:}$$

$$\frac{\partial}{\partial \theta} \ln f_{\mathcal{X}_n}(\vec{x}_n; \theta) = \frac{\partial}{\partial \theta} \ln \prod_{k=1}^n f_{X_k}(x_k; \theta) = \frac{\partial}{\partial \theta} \sum_{k=1}^n \ln f_{X_k}(x_k; \theta) = \sum_{k=1}^n \frac{\partial}{\partial \theta} \ln f_{X_k}(x_k; \theta)$$

وبالاشتقاق مرة أخرى بالنسبة إلى θ نجد الآتي:

$$\frac{\partial}{\partial \theta^2} \ln f_{\mathcal{X}_n}(\bar{x}_n; \theta) = \sum_{k=1}^n \frac{\partial}{\partial \theta^2} \ln f_{X_k}(x_k; \theta)$$

ومن ثمَّ ينتج لدينا أنَّ:

$$\mathbf{I}_{\mathcal{X}_n}(\theta) = \mathbf{E} \left[-\frac{\partial^2}{\partial \theta^2} \ln f_{\mathcal{X}_n}(\bar{x}_n; \theta) \right] = \sum_{k=1}^n \mathbf{E} \left[-\frac{\partial^2}{\partial \theta^2} \ln f_{X_k}(x_k; \theta) \right] = \sum_{k=1}^n \mathbf{I}(\theta) = n \cdot \mathbf{I}(\theta)$$

وبهذا يتمُّ البرهان.

(٩, ١٠, ٢, ٣) ملاحظة

بفرض $\mathbf{I}_T(\theta)$ هي كمية المعلومات التي تُقدِّمها إحصاءة $T = u(\mathcal{X}_n)$ حول المعلمة θ ، فعندئذ يمكن التحقق من أنَّ:

$$\mathbf{I}_{\mathcal{X}_n}(\theta) \geq \mathbf{I}_T(\theta) \quad [9,47]$$

حيث تتحقق إشارة المساواة عندما تكون T إحصاءة كافية للمعلمة θ .

(٩, ١٠, ٢, ٤) مثال

ليكن لدينا $[\Omega, \mathcal{F}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغيِّر عشوائي X خاضع للتوزيع الطبيعي بمتوسط μ وانحراف معياري σ ، ولتكن \mathcal{X}_n عينة من هذا المجتمع، ولنقم بحساب كمية المعلومات التي تُقدِّمها هذه العينة حول المعلمة μ ، وبعد ذلك حول المعلمة σ .

الحل: لدينا من أجل أي $\vec{x}_n = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$ ما يلي:

$$f_{\mathcal{X}_n}(\vec{x}_n; (\mu, \sigma)) = \prod_{k=1}^n f_{X_k}(x_k; (\mu, \sigma)) = \left(\frac{1}{\sigma \sqrt{2\pi}} \right)^n \exp \left[-\frac{1}{2\sigma^2} \sum_{k=1}^n (x_k - \mu)^2 \right]$$

ومن ثمَّ يكون لدينا:

$$\ln f_{\mathcal{X}_n}(\vec{x}_n; (\mu, \sigma)) = n \left(-\ln \sigma - \ln \sqrt{2\pi} \right) - \frac{1}{2\sigma^2} \sum_{k=1}^n (x_k - \mu)^2$$

والتي نجد منها أنَّ:

$$\frac{\partial}{\partial \mu^2} 2 \ln f_{\mathcal{X}_n}(\vec{x}_n; (\mu, \sigma)) = \frac{-n}{\sigma^2}$$

$$\frac{\partial}{\partial \sigma^2} 2 \ln f_{\mathcal{X}_n}(\vec{x}_n; (\mu, \sigma)) = \frac{n}{\sigma^2} - \frac{3}{\sigma^4} \sum_{k=1}^n (x_k - \mu)^2$$

ومن ثمَّ نجد أنَّ كمية المعلومات التي تُقدِّمها العينة \mathcal{X}_n حول المعلمة μ تساوي:

$$\mathbf{I}_{\mathcal{X}_n}(\mu) = \mathbf{E} \left(\frac{n}{\sigma^2} \right) = \frac{n}{\sigma^2}$$

وأما كمية المعلومات التي تُقدِّمها هذه العينة حول المعلمة σ فنَجدها تساوي:

$$\begin{aligned} \mathbf{I}_{\vartheta_n}(\sigma) &= \mathbf{E} \left[\frac{3}{\sigma^4} \sum_{k=1}^n (X_k - \mu)^2 - \frac{n}{\sigma^2} \right] = \frac{3}{\sigma^4} \sum_{k=1}^n \mathbf{E} (X_k - \mu)^2 - \frac{n}{\sigma^2} \\ &= \frac{3}{\sigma^4} \sum_{k=1}^n \underbrace{\mathbf{E} (X - \mathbf{E} X)^2}_{\sigma^2} - \frac{n}{\sigma^2} = \frac{2n}{\sigma^2} \end{aligned}$$

هذا ما تيسَّر تقديمه من أجل الجزء النظري والتطبيقي لهذا الفصل

تمارين الفصل التاسع

١- ليكن $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X بمتوسط μ وانحراف معياري σ ، ولتكن $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ عينة مسحوبة من هذا المجتمع. عندئذ:

أ- إذا أخذنا a_1, a_2, \dots, a_n و $0 < a_n$ مع $\sum_{k=1}^n a_k = 1$ ، ووضعنا $\bar{X} = \sum_{k=1}^n a_k X_k$ ، حيث نلاحظ أن \bar{X} هو المتوسط الموزون للعينة \mathcal{X}_n ، فما هي قيم $E \bar{X}$ و $\text{var } \bar{X}$ ، ومن ثم قارن قيمة $\text{var } \bar{X}$ مع قيمة $\text{var } \bar{X}$ ؟

ب- إذا أخذنا $Y = \left(\frac{X_1 + X_2 + \dots + X_n}{n} \right)^2$ ، فما هي قيمة $E Y$ ؟

ج- إذا أخذنا $Z = \frac{X_1^2 + X_2^2 + \dots + X_n^2}{n}$ ، فما هي قيمة $E Z$ ؟

٢- قمنا بسحب عينة \mathcal{X}_{100} (حجمها مئة) لأشخاص عاملين في مؤسسة تعليمية (جامعة مثلاً)، ومن ثم دَوَّنت عدد ساعات العمل خلال نصف عام دراسي لكل فرد منهم، فوجدنا أن متوسط عدد ساعات عملهم خلال نصف عام دراسي يساوي 1000 ساعة بانحراف معياري قدره 20 ساعة عمل، فلو افترضنا أن عدد ساعات العمل في هذه المؤسسة يتوزع طبيعياً على وجه التقريب، فعندئذ المطلوب ما يلي:

أ- حساب $P(997 \leq \bar{X} \leq 1003)$.

ب- حساب $P(\bar{X} > 1010)$.

ج - بفرض أن المؤسسة أعلمتنا أن الانحراف المعياري لعدد ساعات العمل لديها هو 15 ساعة عمل، فما هي قيمة الاحتمال $P(S^2 < 225)$ ؟

٣- قمنا باستيراد نوع من السلع من مصدرين A و B مستقلين عن بعضهما، حيث ادعى المصدر A أن نسبة السلع غير المطابقة للمواصفات في إنتاجه لا تتجاوز 0.015 بينما ادعى المصدر B أن نسبة السلع غير المطابقة للمواصفات في إنتاجه لا تتجاوز 0.005. قمنا بسحب عينة من السلع المستوردة من المصدر A بحجم 225 سلعة فوجدنا 3 سلع غير مطابقة للمواصفات، وكذلك سحبنا عينة من السلع المستوردة من المصدر B بحجم 289 سلعة فوجدنا 3 سلع غير مطابقة للمواصفات أيضاً، والمطلوب:

أ - ما هو احتمال أن تكون نسبة السلع غير المطابقة للمواصفات في إنتاج المصدر A ما بين 0.02 و 0.04؟

ب - ما هو احتمال أن تكون نسبة السلع غير المطابقة للمواصفات في إنتاج المصدر B أكبر من A بمقدار 0.005؟

ج - ما هو احتمال أن تكون نسبة السلع غير المطابقة للمواصفات في إنتاج المصدرين متساوية؟

د - ما هو احتمال أن يكون الفرق بين نسب السلع غير المطابقة للمواصفات في إنتاج المصنعين أصغر من 0.005؟

هـ - كم يجب أن يكون حجم العينة المسحوبة من المصدر A حتى يصبح احتمال أن تكون نسبة السلع غير المطابقة للمواصفات في

إنتاج المصدر A تساوي 0.015 أكبر من 0.9999؟

٤- في مصنع يوجد خطين لإنتاج المكثفات الكيميائية ذات سعة $47 \mu F$ ميكرو فاراد، فإذا علمت أن الخطين يعملان بشكل مستقل كل منهما عن الآخر، وأن نسبة القطع المعيبة في إنتاج الخط الأول (I) لا تتجاوز 0.05، وأن نسبة القطع المعيبة في إنتاج الخط الثاني (II) لا تتجاوز 0.04، وقمنا بأخذ عينة بحجم $n = 81$ من إنتاج الخط (I) فوجدنا 4 قطع معيبة (معطلة)، ثم أخذنا عينة أخرى من إنتاج الخط (II) بحجم $m = 100$ فوجدنا 5 قطع معيبة، فعندئذ:

أ- احسب احتمال أن تكون نسبة القطع المعيبة في إنتاج المصنع (I) أكبر من 0.05 .

ب- احسب احتمال أن تكون نسبة القطع المعيبة في إنتاج المصنع (II) ما بين 0.03 و 0.05.

ج- احسب احتمال أن يكون الفرق بين نسب القطع المعيبة لإنتاج المصنعين أكبر من 0.15.

٥- ليكن $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X دالة كثافته الاحتمالية معطاة من خلال العلاقة الآتية:

$$f_X(x; \theta) := \theta x^{\theta-1} \mathbf{I}_{(0,1)}(x) \quad ; \theta > 0$$

ولتكن \mathcal{X}_n عينة من هذا المجتمع، ولنأخذ الإحصاءة $T = u(\mathcal{X}_n) = \prod_{k=1}^n X_k$ ، والمطلوب بين إن كانت هذه الإحصاءة إحصاء كافية للمعلمة θ أم لا؟

٦- ليكن لدينا $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X خاضع لتوزيع برنولي بمعلمة $0 < p < 1$ ، ولتكن \mathcal{X}_n عينة من هذا المجتمع، والمطلوب حساب كمية معلومات فيشر التي تقدمها العينة \mathcal{X}_n .

٧- ليكن لدينا $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X خاضع لتوزيع بواسون بمعلمة $0 < \lambda$ ، ولتكن \mathcal{X}_n عينة من هذا المجتمع، والمطلوب حساب كمية معلومات فيشر التي تقدمها العينة \mathcal{X}_n .

٨- ليكن لدينا $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X خاضع للتوزيع الأسّي بمعلمة $0 < \lambda$ ، ولتكن \mathcal{X}_n عينة من هذا المجتمع، والمطلوب حساب كمية معلومات فيشر التي تقدمها العينة \mathcal{X}_n .

الفصل العاشر

مدخل إلى نظرية التقدير

AN INTRODUCTION TO ESTIMATION THEORY

تمهيد

نذكر أولاً إلى أنه عندما نذكر كلمة **عينة** (أو **عينات**) فإننا نقصد بذلك أنها **عينة** (أو **عينات**) عشوائية، ومن ثم فإن البيانات التي تكونها هي بيانات عشوائية حتماً وليست كيفية كما كانت في الفصول الثلاث الأولى من هذا الكتاب. كذلك عندما نأخذ \mathcal{X}_n عينة عشوائية فإننا نقصد بذلك أنها بسيطة بحجم يساوي n ، وأكثر من ذلك عندما نذكر كلمة مجتمع فإننا نقصد بذلك أنه مجتمع إحصائي.

لقد لاحظنا أنه من أجل $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمع معطى فإن القياسات الاحتمالية P_θ تفرض علينا معرفة كل المعلومات عن المعلمة θ بحيث يصبح معه النموذج الرياضي النظري $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مناسباً للمجتمع الذي قيد الدراسة، وبما أن المعلمة θ يمكن لها أن تكون متجهها $\theta = (\theta_1, \theta_2, \dots, \theta_k)$ من \mathbb{R}^k فإن مركبات هذا المتجه قد تكون مجهولة كلياً أو جزئياً في الحالة العامة، ولهذا السبب يجب علينا سحب عينات من المجتمع من أجل الحصول على معلومات تساعدنا في تقدير قيم هذه المعالم المجهولة، بمعنى أن المسألة التي لدينا آلت إلى تقدير هذه المعالم المجهولة من خلال سحب عينات من المجتمع. إن القطاع الذي يهتم بتقدير معالم المجتمع Population Parameters وتقديم الاختبارات المتعلقة بهذه المعالم، ومن ثم اتخاذ القرارات المناسبة بشأن المسألة الإحصائية التي قيد الدراسة، يُعرف باسم **الإحصاء الاستدلالي** Inferential Statistics وفي بعض المراجع يُذكر باسم **الاستدلال الإحصائي** Statistical Inference، ويرتكز هذا الفرع من الإحصاء الرياضي على الموضوعين الآتين:

- نظرية التقدير.

- اختبارات الفرضيات الإحصائية.

علماً أن موضوع اختبارات الفرضيات الإحصائية يهتم بتقديم اختبارات حول فرضيات محددة تتعلق بالمجتمع المدروس أو بمعامله المجهولة (سيخصص الفصل التالي لهذا الموضوع). أما نظرية التقدير فإنها تهتم بشكل أساسي بتعيين الإحصاءات التي تقدر قيم المعالم المجهولة للمجتمع بالإضافة إلى تقديم بعض الصفات المميزة لهذه المقدرات، وكذلك تحديد فترات تنتمي إليها تلك المعالم المجهولة باحتمال معلوم مستندة في ذلك على مقدرات تلك المعالم المجهولة.

نشير هنا إلى أننا لن نسترسل كثيراً في شرح فقرات هذا الفصل حيث يمكن لمن يرغب بالمزيد الرجوع إلى المراجع ذات الصلة ومنها [6]، [22]، [24]، [33]، [37]، [40]، [45]، [47]، [62] و [66] في فهرس مراجع هذا الكتاب، وأخيراً نشير إلى أننا سنركز في دراستنا على تقدير المعالم المجهولة لمجتمع وفقاً للمسارات الآتية:

١- كيفية تعيين مقدر معلمة مجتمع.

٢- البحث في بعض الصفات المميزة للمقدرات.

٣- تقديم فترات تنتمي إليها المعالم المجهولة للمجتمع باحتمال معلوم، وهذه الفترات تدعى **فترات الثقة**.

(١٠, ١) **تعيين مقدر معلمة مجتمع إحصائي****Determination an Estimator of Population Parameter**

نقوم فيما يلي بتقديم طريقتين فقط لتعيين مقدر معلمة مجتمع وهما:

١- طريقة العزوم Moments Method.

٢- طريقة الأرجحية العظمى Maximum Likelihood Method.

علماً أنه توجد طرائق أخرى تستخدم في تعيين مقدر معلمة مجتمع حيث يمكن للقارئ الاطلاع على بعضها بالرجوع إلى المراجع ذات الصلة ومنها ذكر آنفاً.

(١٠, ١, ١) **طريقة العزوم في تعيين مقدرات معالم مجتمع**

ليكن $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X ، وسنفترض أن θ متجه بـ k مركبة، أي $\theta = (\theta_1, \theta_2, \dots, \theta_k)$ ، ولنأخذ $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ عينة من هذا المجتمع. عندئذ تقوم طريقة العزوم في تعيين مقدر معلمة المجتمع θ على الأسس الآتية:

أ- حساب العزم الابتدائي من المرتبة r لكل من \mathcal{X}_n و X من أجل جميع القيم $r \in N_k$.

ب- حل جملة المعادلات الآتية (حلاً مشتركاً):

$$M^{(r)} = \mu^{(r)} |_{\theta = \hat{\theta}} \quad ; \forall r \in N_k \quad [10,1]$$

علماً أن $M^{(r)}$ و $\mu^{(r)}$ هما العزم الابتدائي من المرتبة r لـ \mathcal{X}_n و X على الترتيب.

ج- بفرض أن $\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_k$ هي الحلول الناتجة عن جملة المعادلات [10,1]، فإننا نضع $\hat{\theta} = (\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_k)$ ، فعندئذ يُقال عن $\hat{\theta}$ إنه **مقدر المعلمة θ** وفقاً لطريقة العزوم، وأما الحلول $\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_k$ فإنها تدعى **المقدرات الإحصائية** Statistical Estimators (أو **المقدرات**) للمعالم $\theta_1, \theta_2, \dots, \theta_k$ على الترتيب.

إن هذه الطريقة في تقدير معلمة مجتمع هي أول الطرائق التي قدمت لتعيين مقدر معلمة مجتمع، وعلى وجه التحديد تعود إلى الإحصائي الإنكليزي بيرسون.

(١٠, ١, ١, ١) **أمثلة**

١- ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X له توزيع طبيعي $N(\mu, \sigma)$ ، ولنأخذ \mathcal{X}_n عينة من هذا المجتمع، ولنقم بتعيين مقدري المعلمتين μ و σ .

الحل: من أجل تعيين مقدري المعلمتين μ و σ يجب علينا حل جملة المعادلات [10,1] الخاصة بهذه المسألة (هنا لدينا معادلتان فقط لأنه لدينا معلمتان فقط)، وبما أنه لدينا معلمتين فإنه يتوجب علينا تعيين المقادير الآتية:

$$M = \frac{X_1 + X_2 + \dots + X_n}{n} = \bar{X} \quad \& \quad M^{(2)} = \frac{X_1^2 + X_2^2 + \dots + X_n^2}{n} = \overline{X^2}$$

$$\mu = EX = \mu \quad \& \quad \mu^{(2)} = EX^2 = \sigma^2 + \mu^2$$

ومن ثم يكون لدينا:

$$M = \mu |_{(\mu, \sigma) = (\hat{\mu}, \hat{\sigma})} \Rightarrow \frac{X_1 + X_2 + \dots + X_n}{n} = \mu |_{(\mu, \sigma) = (\hat{\mu}, \hat{\sigma})} \Rightarrow \bar{X} = \hat{\mu} \quad (1)$$

وكذلك:

$$\mathbf{M}^{(2)} = \mu^{(2)} \Big|_{(\mu, \sigma) = (\hat{\mu}, \hat{\sigma})} \Rightarrow \frac{X_1^2 + X_2^2 + \dots + X_n^2}{n} = \sigma^2 + \mu^2 \Big|_{(\mu, \sigma) = (\hat{\mu}, \hat{\sigma})} \Rightarrow \overline{X^2} = \hat{\sigma}^2 - \hat{\mu}^2 \quad (2)$$

وبالتعويض في (2) عن $\hat{\mu}$ بما يساويها في العلاقة (1) ينتج لدينا أن $\hat{\sigma}^2 = \overline{X^2} - \bar{X}^2$ ، ومن ثم يكون \bar{X} هو مُقدّر المعلمة μ ، وأما مُقدّر المعلمة σ فهو $\hat{\sigma} = +\sqrt{\overline{X^2} - \bar{X}^2}$ وبالتالي فإنَّ المتجه:

$$\hat{\theta} = \left(\bar{X}, \sqrt{\overline{X^2} - \bar{X}^2} \right)$$

هو مُقدّر المعلمة $\theta = (\mu, \sigma)$ وفقاً لطريقة العزوم.

٢- ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي $X \sim \mathbf{B}(n, p)$ ، ولنأخذ عينة من هذا المجتمع، فعندئذ لتعيين مُقدري المعلمتين n و p يجب علينا حل جملة المعادلات [10,1] الخاصة بهذه المسألة (هنا لدينا معادلتان فقط لأنَّ لدينا معلمتان فقط)، وبما أنَّه لدينا معلمتين فإنَّه يتوجب علينا تعيين المقدارين الآتية:

$$\begin{aligned} \mathbf{M} = \frac{X_1 + X_2 + \dots + X_n}{n} = \bar{X} & \quad \& \quad \mathbf{M}^{(2)} = \frac{X_1^2 + X_2^2 + \dots + X_n^2}{n} \triangleq \overline{X^2} \\ \mu = \mathbf{E}X = n \cdot p & \quad \& \quad \mu^{(2)} = \mathbf{E}X^2 = n p (1-p) + n^2 p^2 \end{aligned}$$

ومن ثمَّ يكون:

$$\mathbf{M} = \mu \Big|_{(n, p) = (\hat{n}, \hat{p})} \Rightarrow \bar{X} = n \cdot p \Big|_{(n, p) = (\hat{n}, \hat{p})} \Rightarrow \bar{X} = \hat{n} \cdot \hat{p} \quad (1)$$

وكذلك لدينا:

$$\mathbf{M}^{(2)} = \mu^{(2)} \Big|_{(n, p) = (\hat{n}, \hat{p})} \Rightarrow \overline{X^2} = n p (1-p) + n^2 p^2 \Big|_{(n, p) = (\hat{n}, \hat{p})} \Rightarrow \overline{X^2} = \hat{n} \hat{p} (1-\hat{p}) + \hat{n}^2 \hat{p}^2 \quad (2)$$

وبالحل المشترك للمعادلتين (1) و (2) نجد منهما الحلين $\hat{n} = \frac{1}{\bar{X} - \overline{X^2}}$ و $\hat{p} = \frac{\bar{X} - \overline{X^2}}{\bar{X}}$ ، والذين يقدران المعلمتين n و p ، وبالتالي فإنَّ المتجه:

$$\hat{\theta} = \left(\frac{1}{\bar{X} - \overline{X^2}}, \frac{\bar{X} - \overline{X^2}}{\bar{X}} \right)$$

هو مُقدّر المعلمة $\theta = (n, p)$ وفقاً لطريقة العزوم حيث نلاحظ هنا أنَّه يجب أن يكون $\overline{X^2} < \bar{X}$.

٣- ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي $X \sim \mathbf{P}(\lambda)$ (أي إنه لدينا مجتمع بواسوني بمعلمة $\lambda > 0$)، ولنأخذ عينة من هذا المجتمع، فعندئذ لتعيين مُقدّر المعلمة λ يجب علينا حل جملة المعادلات [10,1] الخاصة بهذه المسألة، ولكن بما أنَّه لدينا معلمة واحدة فقط فإنَّه يكفي حل المعادلة $\mathbf{M} = \mu \Big|_{\lambda = \hat{\lambda}}$ فقط، حيث لدينا:

$$\mathbf{M} = \bar{X} \quad \& \quad \mu = \mathbf{E}X = \lambda$$

ومن ثمَّ نحصل على الحل $\hat{\lambda} = \bar{X}$ ، وبالتالي فإنَّ \bar{X} هو مُقدّر المعلمة λ وفقاً لطريقة العزوم.

٤- بفرض أنَّ $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمع موصوفاً من خلال متغير عشوائي $X \sim \mathbf{Ex}(\lambda)$ (أي إنه لدينا مجتمع أسّي بمعلمة $\lambda > 0$)،

ولنأخذ \mathcal{X}_n عينة من هذا المجتمع، فعندئذ لتعيين مُقدّر معلّمة هذا المجتمع (وفقاً لطريقة العزوم) يكفي حل المعادلة $M = \mu |_{\lambda = \hat{\lambda}}$ ، حيث لدينا:

$$M = \bar{X} \quad \& \quad \mu = EX = \frac{1}{\lambda}$$

فنحصل نتيجة لذلك على الحل $\hat{\lambda} = \frac{1}{\bar{X}}$ ، ومن ثم يكون $\hat{\lambda} = \frac{1}{\bar{X}}$ هو مُقدّر المعلّمة λ وفقاً لطريقة العزوم.

(١٠, ١, ٢) ملاحظات

١- إنَّ استخدام هذه الطريقة غير ممكن من أجل المجتمعات التي لا تملك عزوماً ابتدائية (ومن هنا المجتمعات التي تتبع توزيع كوشي).

٢- إنَّ المقدّرات العزومية لمعلّمة مجتمع ليست وحيدة في الحالة العامة، إذ يمكن حسابها باستخدام العزوم المركزية أيضاً.

(١٠, ١, ٢) طريقة الأرجحية العظمى في تعيين مُقدّرات معالم مجتمع

Maximum Likelihood Method for Estimations of Population Parameters

إنَّ طريقة الأرجحية العظمى (أو الاحتمال الأكبر) تُعدّ من أكثر الطرائق المستخدمة في تعيين مُقدّرات معالم المجتمعات لما تتمتع به من صفات مرغوبة في المقدّرات (التي سنوردها فيما بعد)، ولكن قبل البدء بتقديم هذه الطريقة سنقدّم مثلاً بسيطاً يوضح لنا مفهوم الأرجحية العظمى.

(١٠, ١, ٢, ١) مثال

في مدينة ما تبين أنَّ نسبة الذكور والإناث هما 52% و 48% ولكن دون معرفة أي منهما للذكور أو للإناث، ولنفترض أنَّ حصولنا على ذكر عند سحب فرد من هذا المجتمع يُعدّ نجاحاً. عندئذ بفرض أنَّ جميع عناصر هذا المجتمع مستقلة بعضها عن البعض الآخر، فإنَّ كل عملية سحب لفرد من هذا المجتمع هي تجربة برنولية بمعلّمة $p = ?$ ، فإذا كان X متغيّر عشوائي واصف لهذا المجتمع فإنّه سيكون لـ X توزيع برنولي بدالة كثافة احتمالية $f_X(x; p)$ ، أي إنّه لدينا:

$$f_X(x; p) = P(X = x; p) = p^x (1-p)^{1-x} I_{\{0,1\}}(x)$$

علماً أنَّ p ينتمي إلى المجموعة $R \supseteq \Theta = \{0.48, 0.52\}$ ، ومن ثمَّ يكون لدينا ما يلي:

$$\text{If } p = 0.48 \Rightarrow f_X(0; p) = 0.52 \quad \& \quad f_X(1; p) = 0.48$$

$$\text{If } p = 0.52 \Rightarrow f_X(0; p) = 0.48 \quad \& \quad f_X(1; p) = 0.52$$

وهكذا نلاحظ أنّه:

١- إذا كان $x = 0$ فإننا نرجّح استخدام القيمة $\hat{p} = 0.48$ على القيمة $\hat{p} = 0.52$ كتقدير لـ p لأنَّ للدالة $f_X(0; p)$ احتمال أكبر (ومن ثمَّ أرجحية أكبر) من أجل هذه الحالة.

٢- إذا كان $x = 1$ فإننا نرجّح استخدام القيمة $\hat{p} = 0.52$ على القيمة $\hat{p} = 0.48$ كتقدير لـ p لأنَّ للدالة $f_X(1; p)$ احتمال أكبر (ومن ثمَّ أرجحية أكبر) من أجل هذه الحالة.

الآن وبشكل مماثل يمكننا مناقشة الحالة التي توافق سحب عينة $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ من مجتمع، فعلى سبيل المثال لو عدنا إلى المثال السابق، وقمنا بسحب عينة حجمها يساوي 5، أي لدينا $\mathcal{X}_n = (X_1, X_2, X_3, X_4, X_5)$ ، فعندئذ يكون للمتغيّر العشوائي الواصف لهذا المجتمع توزيع حدائي (لأنّه لدينا تكرارات مستقلة لتجارب برنولية)، ومن ثمَّ يكون لـ $f_X(\bar{x}_5; p)$ العرض الآتي:

$$f_X(x;p) = \sum_{x=0}^5 \binom{5}{x} p^x (1-p)^{5-x} I_{\{0,1,2,3,4,5\}}(x)$$

وعلى سبيل التبسيط والتوضيح يمكننا عرض النتائج لهذه الدراسة من خلال الجدول الآتي:

الجدول (١٠، ١)

	p	0.48	0.52
	$f_X(x;p)$	$f_X(x;0.48)$	$f_X(x;0.52)$
x	0	0.0380204	0.0254804
	1	0.1754780	0.1380188
	2	0.3239608	0.2990408
	3	0.2990408	0.3239608
	4	0.1380188	0.1754788
	5	0.0254804	0.0380204

علماً أننا استخدمنا الحاسبة الإلكترونية للوصول إلى قيم دقيقة للاحتتمالات. حيث نلاحظ بوضوح أنه إذا كان $x=0$ أو $x=1$ أو $x=2$ فإننا نرجح استخدام القيمة $\hat{p}=0.48$ على القيمة $\hat{p}=0.52$ كتقدير لـ p لأنه للدالة $f_X(x;p)$ احتمال أكبر (ومن ثم أرجحية أكبر) من أجل هذه القيم لـ x ، وأما إذا كان $x=3$ أو $x=4$ أو $x=5$ فإننا نرجح استخدام القيمة $\hat{p}=0.52$ على القيمة $\hat{p}=0.48$ كتقدير لـ p لأنه للدالة $f_X(x;p)$ احتمال أكبر من أجل هذه الحالات الثلاث الأخيرة.

(١٠، ١، ٢، ٢) تعريف (دالة الأرجحية لعينة Likelihood Function of a sample)

ليكن لدينا $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X ، ولتكن $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ عينة من هذا المجتمع، ولنضع بالتعريف ما يلي:

$$L(\bar{x}_n; \theta) = f_{\mathcal{X}_n}(\bar{x}_n; \theta) = \prod_{k=1}^n f_X(x_k; \theta) \quad [10,2]$$

علماً أن \bar{x}_n هي القيمة الملاحظة للعينة العشوائية \mathcal{X}_n ، فعندئذ يُطلق على الدالة $L(\bar{x}_n; \theta)$ اسم **دالة الأرجحية** للعينة \mathcal{X}_n .

بالرغم من أن العديد من المؤلفات استخدمت تسمية **دالة الأرجحية** إلا أن مؤلفات عربية أخرى استخدمت تسميات أخرى بدلاً من عبارة دالة الأرجحية، ومن هذه التسميات: **دالة الجوازية** أو **دالة المعقولة** أو **دالة الإمكان**، وقد اخترنا التسمية المذكورة آنفاً لاعتقادنا بأرجحية معناها مع التفسير العلمي لتلك الدالة.

(١٠، ١، ٢، ٣) تعريف (مُقدر الأرجحية العظمى Maximum Likelihood Estimator)

ليكن لدينا $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X ، ولتكن $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ عينة من هذا المجتمع، وبفرض أن $L(\bar{x}_n; \theta)$ هي دالة الأرجحية للعينة \mathcal{X}_n ، فعندئذ يُطلق على الحل $\hat{\theta}$ الذي من أجله يكون لدينا:

$$L(\bar{x}_n; \hat{\theta}) \geq L(\bar{x}_n; \theta) \quad \text{for all } \theta \neq \hat{\theta}$$

اسم **مُقدر الأرجحية العظمى** للمعلمة θ ، حيث يُستعاض عن \bar{x}_n بـ \mathcal{X}_n في الصيغة النهائية لـ $\hat{\theta}$.

إن هذا المبدأ في التقدير يعني أننا سنختار من مُقدِّرات المعلمة θ تلك المقدِّرات التي يكون من أجلها للعينة \mathcal{X}_n أكبر قيمة احتمالية، وهذا يعني أنه يمكننا أن نصيغ العلاقة الأخيرة على النحو الآتي:

$$L(\vec{x}_n; \hat{\theta}) = \max_{\theta \in \Theta} \left\{ L(\vec{x}_n; \theta) \mid_{\theta = \hat{\theta}} \right\} \quad [10,3]$$

(١٠, ١, ٢, ٤) ملاحظات

١- تبدي هذه الطريقة فعالية كبيرة مع التوزيعات التي لها شكل دوال أسية.

٢- من الحالات المهمة أيضاً عند تعيين مُقدّرات الأرجحية العظمى، تلك الحالة التي تكون فيها دالة الأرجحية $L(\vec{x}_n; \theta)$ قابلة للاشتقاق الجزئي بالنسبة إلى θ ، إذ إننا نعلم أن الدالة $L(\vec{x}_n; \theta)$ تأخذ قيمة عظمى عندما يكون $\frac{\partial L(\vec{x}_n; \theta)}{\partial \theta} = 0$ ، ومن ثمّ يمكن تعيين مُقدّر الأرجحية العظمى $\hat{\theta}$ للمعلمة θ من خلال العلاقة الآتية:

$$\left. \frac{\partial L(\vec{x}_n; \theta)}{\partial \theta} \right|_{\theta = \hat{\theta}} = 0 \quad [10,4]$$

وفي حال كان لدينا $\theta = (\theta_1, \theta_2, \dots, \theta_k)$ فإنّه من أجل تطبيق هذه الملاحظة يجب أن تكون الدالة $L(\vec{x}_n; \theta)$ قابلة للاشتقاق الجزئي بالنسبة إلى كلّ من المُركّبات $\theta_1, \theta_2, \dots, \theta_k$ حيث يكون للدالة $L(\vec{x}_n; \theta)$ قيمة عظمى عندما تكون:

$$\frac{\partial L(\vec{x}_n; \theta)}{\partial \theta_i} = 0 \quad ; \forall i \in \mathbb{N}_k \quad [10,5]$$

وحينئذ تُعيّن مُقدّرات الأرجحية العظمى $\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_k$ الموافقة للمعالم $\theta_1, \theta_2, \dots, \theta_k$ (على الترتيب) من خلال حل جملة المعادلات الآتية:

$$\left. \frac{\partial L(\vec{x}_n; \theta)}{\partial \theta_1} \right|_{\theta = \hat{\theta}} = 0 \quad \& \quad \left. \frac{\partial L(\vec{x}_n; \theta)}{\partial \theta_2} \right|_{\theta = \hat{\theta}} = 0 \quad \& \quad \dots \quad \& \quad \left. \frac{\partial L(\vec{x}_n; \theta)}{\partial \theta_k} \right|_{\theta = \hat{\theta}} = 0$$

وبعد ذلك نضع $\hat{\theta} = (\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_k)$.

٣- نعلم أنّه إذا كانت g دالة حقيقية موجبة ومعرفة على \mathbb{R} ، وكان $\left. \frac{\partial g(x)}{\partial x} \right|_{x=x_0} = 0$ ، فإنّه العلاقة $\left. \frac{\partial \ln g(x)}{\partial x} \right|_{x=x_0} = 0$ ستكون محققة أيضاً، ومن ثمّ يمكننا استخدام دالة اللوغاريتم الطبيعي لتعيين مُقدّرات الأرجحية العظمى من خلال حل جملة المعادلات الآتية:

$$\left. \frac{\partial \ln L(\vec{x}_n; \theta)}{\partial \theta} \right|_{\theta = \hat{\theta}} = 0 \quad [10,6]$$

وفي حال كانت θ متجهاً $\theta = (\theta_1, \theta_2, \dots, \theta_k)$ فإننا نستخدم العلاقات الآتية:

$$\left. \frac{\partial \ln L(\vec{x}_n; \theta)}{\partial \theta_1} \right|_{\theta = \hat{\theta}} = 0 \quad \left. \frac{\partial \ln L(\vec{x}_n; \theta)}{\partial \theta_2} \right|_{\theta = \hat{\theta}} = 0 \quad \vdots \quad \left. \frac{\partial \ln L(\vec{x}_n; \theta)}{\partial \theta_k} \right|_{\theta = \hat{\theta}} = 0 \quad [10,7]$$

(٥, ٢, ١, ١٠) أمثلة

١- ليكن $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X دالة كثافته الاحتمالية مُعطاة من خلال العلاقة الآتية:

$$f_X(x; \theta) = \frac{1}{\theta} e^{-\frac{x}{\theta}} \mathbf{I}_{(0, +\infty)}(x) \quad ; \forall x \in \mathbb{R}$$

ولتكن \mathcal{X}_n عينة من هذا المجتمع، ولنقم بتعيين دالة الأرجحية لهذه العينة.


الحل: لدينا من تعريف دالة الأرجحية لعينة ما يلي:

$$L(\bar{x}_n; \theta) = f_{\mathbb{X}_n}(\bar{x}_n; \theta) = \prod_{k=1}^n f_X(x_k; \theta) = \left(\frac{1}{\theta}\right)^n \exp\left[-\frac{1}{\theta} \sum_{k=1}^n x_k\right] \cdot \prod_{k=1}^n \mathbf{I}_{(0, \infty)}(x_k)$$

فعلى سبيل المثال لو أخذنا $x = 3$ وبفرض أن $\bar{x}_3 = (2, 4, 3.6)$ ، فإنه سيكون لدينا:

$$L((2, 4, 3.6); \theta) = \frac{1}{\theta^3} e^{-\frac{9.6}{\theta}}$$

حيث يمكن تبيان أن لهذه الدالة قيمة عظمى عند النقطة $x = 3.2$ (انظر الشكل الآتي).



الشكل (١, ١٠)

٢- ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً له توزيع منتظم مستمر على فترة $\mathbb{R} \supseteq (a, b)$ ، ولتكن \mathcal{X}_n عينة من هذا المجتمع، ولنقم بتعيين مُقدّرات الأرجحية العظمى لكل من a و b .

الحل: من أجل ذلك لدينا:

$$L(\bar{x}_n; (a, b)) = f_{\mathbb{X}_n}(\bar{x}_n; \theta) = \prod_{k=1}^n f_X(x_k; \theta) = \left(\frac{1}{b-a}\right)^n \cdot \prod_{k=1}^n \mathbf{I}_{(a, b)}(x_k)$$

ومن ثم يكون لهذه الدالة قيمة عظمى عندما يكون $a \leq x_1, x_2, \dots, x_n \leq b$ ، فإذا افترضنا أن \hat{a} و \hat{b} هما مُقدّرات الأرجحية العظمى لـ a و b على الترتيب، فإنه سيكون لدينا المتباينتين $\hat{a} \leq x_1, x_2, \dots, x_n$ و $\hat{b} \geq x_1, x_2, \dots, x_n$ مُحققتين، ومن ثم لو قمنا بترتيب القيم الملحوظة لهذه العينة من الأصغر إلى الأكبر على النحو $x_1^* > \dots > x_2^* > x_1^*$ ، فعندئذ سيكون $\hat{a} \leq x_1^* < x_2^* < \dots < x_n^* \leq \hat{b}$ وبالتالي ينتج لدينا أن:

$$\hat{a} = X_1^* = \min \{X_1, X_2, \dots, X_n\}$$

$$\hat{b} = X_n^* = \max \{X_1, X_2, \dots, X_n\}$$

وبهذا يكون قد تم تعيين مُقدّرات معالم هذا المجتمع.

٣- ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X خاضع لتوزيع بواسون بمعلمة $\lambda > 0$ ، ولنأخذ \mathcal{X}_n عينة من هذا المجتمع، ولنقم بتعيين مُقدّر الأرجحية العظمى للمعلمة λ .

الحل: من أجل ذلك لدينا:

$$L(\vec{x}_n; \lambda) = \prod_{k=1}^n f_X(x_k; \lambda) = e^{-n \cdot \lambda} \lambda^{\sum_{k=1}^n x_k} \left(\prod_{k=1}^n (x_k!) \right)^{-1} \quad (*)$$

وبأخذ اللوغاريتم الطبيعي لطرفي العلاقة الأخيرة يصبح لدينا:

$$\ln L(\vec{x}_n; \lambda) = -n \cdot \lambda + \left(\sum_{k=1}^n x_k \right) \ln \lambda - \sum_{k=1}^n \sum_{\ell=1}^k \ln x_{\ell}$$

حيث يجب أن يكون $\left. \frac{\partial \ln L(\vec{x}_n; \lambda)}{\partial \lambda} \right|_{\lambda=\hat{\lambda}} = 0$ ، وباشتقاق العلاقة (*) بالنسبة إلى المعلمة λ ينتج لدينا:

$$\left(-n + \frac{1}{\lambda} \sum_{k=1}^n x_k \right) \Big|_{\lambda=\hat{\lambda}} = 0 \Rightarrow \hat{\lambda} = \frac{1}{n} \sum_{k=1}^n x_k \Rightarrow \hat{\lambda} = \bar{X}$$

ومن ثم يكون $\hat{\lambda} = \bar{X}$ هو مُقدّر الأرجحية العظمى لمعلمة المجتمع البواسوني.

٤- ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X خاضع للتوزيع الطبيعي بمعلمتين $\mu \in \mathbb{R}$ و $\sigma > 0$ ، ولنأخذ \mathcal{X}_n عينة من هذا المجتمع، ولنقم بتعيين مُقدّر الأرجحية العظمى لكل من μ و σ .

الحل: من أجل ذلك لدينا:

$$L(\vec{x}_n; (\mu, \sigma)) = \prod_{k=1}^n f_X(x_k; (\mu, \sigma)) = \left(\frac{1}{\sigma \sqrt{2\pi}} \right)^n \exp \left[-\frac{1}{2\sigma^2} \sum_{k=1}^n (x_k - \mu)^2 \right]$$

وبأخذ اللوغاريتم الطبيعي لطرفي العلاقة الأخيرة يصبح لدينا:

$$\ln L(\vec{x}_n; (\mu, \sigma)) = -n \cdot \ln \sigma - n \cdot \ln \sqrt{2\pi} - \frac{1}{2\sigma^2} \sum_{k=1}^n (x_k - \mu)^2 \quad (1)$$

حيث يجب أن يكون لدينا:

$$\left. \frac{\partial \ln L(\vec{x}_n; (\mu, \sigma))}{\partial \mu} \right|_{(\mu, \sigma) = (\hat{\mu}, \hat{\sigma})} = 0 \quad \& \quad \left. \frac{\partial \ln L(\vec{x}_n; (\mu, \sigma))}{\partial \sigma} \right|_{(\mu, \sigma) = (\hat{\mu}, \hat{\sigma})} = 0$$

وبالاشتقاق الجزئي لطرفي العلاقة (1) بالنسبة إلى المعلمة μ و σ كل على حده يكون لدينا العلاقتين الآتيتين على الترتيب:

$$\sum_{k=1}^n (x_k - \mu) \Big|_{\mu=\hat{\mu}} = 0 \quad \& \quad \sum_{k=1}^n \left(\frac{(x_k - \mu)^2}{\sigma^3} - \frac{n}{\sigma} \right) \Big|_{\mu=\hat{\mu}, \sigma=\hat{\sigma}} = 0 \quad (2)$$

وبحل جملة المعادلتين (2) حلاً مشتركاً نحصل على النتائج الآتية:

$$\hat{\mu} = \frac{1}{n} \sum_{k=1}^n x_k \Rightarrow \hat{\mu} = \bar{X} \quad \& \quad \hat{\sigma}^2 = \frac{1}{n} \sum_{k=1}^n (x_k - \bar{X})^2 \Rightarrow \hat{\sigma}^2 = \tilde{S}^2 = \frac{n-1}{n} S^2$$

أي إنه لدينا مُقدّر الأرجحية العظمى لـ μ هو $\hat{\mu} = \bar{X}$ ، وأما مُقدّر الأرجحية العظمى لـ σ فهو $\hat{\sigma} = \tilde{S} = \sqrt{\frac{n-1}{n}} S$.

(١٠, ١, ٢, ٦) ملاحظات

- ١- فيما يلي وعندما نذكر كلمة مُقدّر لمعلّمة فإنّه علينا الأخذ بالحسبان أنّ هذا المُقدّر هو إحصاءة حتى لو لم يُذكر بهذا المسمّى.
- ٢- فيما يلي سنورد بعض الملاحظات دون الخوض في تعليقاتها، حيث يمكن لمن يودّ الاطلاع على التعليقات الرجوع إلى المراجع ذات الصلة.
- أ- إذا كان $\hat{\theta}$ هو مُقدّر الأرجحية العظمى للمعلّمة θ وكان لدينا $h = g(\theta)$ دالة وحيدة القيمة في θ ، فعندئذ يكون $\hat{h} = g(\hat{\theta})$ هو مُقدّر الأرجحية العظمى للدالة h أيضاً.
- ب- في حال عدم تطابق نتائج طريقة العزوم مع نتائج طريقة الأرجحية العظمى في تعيين مُقدّرات معّالم مجتمع ما، فإنّنا نأخذ المُقدّرات التي نحصل عليها من طريقة الأرجحية العظمى؛ وذلك لأنّه ثبت تجريبياً أنّ مُقدّرات الأرجحية العظمى هي أفضل من المُقدّرات التي نحصل عليها من طريقة العزوم.
- ج- عندما يكون حجم العينة كبيراً بقدر كافٍ فإنّ سيكون لـ $\hat{\theta}$ (مُقدّر الأرجحية العظمى للمعلّمة θ) توزيع طبيعي على وجه التقريب.


(١٠, ٢) التقدير النقطي

Point Estimation


لقد قدّمنا في الفقرة السابقة بعض الطرائق المستخدمة في تعيين مُقدّر معلّمة مجتمع، فلو أمعنا النظر في مُقدّرات المعّالم لوجدنا أنّه من أجل عينة محدّدة \mathcal{X}_n ستكون قيم هذه المُقدّرات هي قيم تقديرية لمعّالم المجتمع، وبدورها يمكن أن تُمثّل بنقاط على المحور الحقيقي؛ ولذلك يُطلق على هذه المُقدّرات اسم **مُقدّرات نقطية** لمعّالم المجتمع، أي إنّ هذه الطريقة في التقدير تهدف إلى تقدير قيمة المعلّمة للمجتمع بقيمة محدّدة تماماً. لكن قد يحدث (في كثير من الحالات) أن يكون لدينا أكثر من مُقدّر لمعلّمة المجتمع، ومن ثمّ السؤال الذي يطرح هنا: أي من هذه المُقدّرات سنختار أو نفضل؟

إنّ السؤال السابق يعنى أنّه أي من هذه المُقدّرات لمعلّمة مجتمع يُعطينا استنباطاً أفضل للمعلومات حول هذه المعلّمة؟

فلو افترضنا أنّه لدينا الإحصاءة $T_1 = g_1(\mathcal{X}_n)$ و $T_2 = g_2(\mathcal{X}_n)$ بدالتي كثافة احتمالية $g_1(t)$ و $g_2(t)$ على الترتيب، فإنّه من الممكن أن يكون توزيع أحدهما متمركزاً عند قيمة المعلّمة θ في حين أنّ الآخر متمركز بعيداً عن θ (انظر الشكل (١٠, ٢. أ)، وحتى في حال تمركز توزيع كل منهما عند القيمة θ ، فمن الممكن أن يكون تباين توزيع الإحصاءة T_1 أكبر من تباين توزيع الإحصاءة T_2 ، ومن ثمّ ستكون دالة الكثافة $g_1(t)$ منبسطة بالمقارنة مع دالة الكثافة $g_2(t)$ (انظر الشكل (١٠, ٢. ب)).



الشكل (١٠, ٢) ب)



الشكل (١٠, ٢) أ)

إنَّ الإجابة على السؤال السابق تفرض علينا إعطاء معايير تُميِّز من خلالها صفات كل مُقدَّر ومن ثمَّ اختيار المقدَّر الأنسب لدراستنا.

(١٠, ٢, ١) المقدَّرات غير المنحازة (أو المُتصفة)

إنَّ أولى الصفات التي سنذكرها هي صفة **عدم التحيز** (أو **الإنصاف**) Unbiasedness التي سنعرِّفها بعد تقديم ما يُعرف باسم **مقدَّار التحيز** لمقدَّر معلَّمة مجتمع.

(١٠, ٢, ١, ١) تعريف (مقدَّار التحيز لمقدَّر معلَّمة مجتمع إحصائي) Unbiasedness Quantity of a Parameter

ليكن لدينا $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغيِّر عشوائي X ، ولنأخذ \mathcal{X}_n عينة من هذا المجتمع، ولنفترض أنَّ $T = g(\mathcal{X}_n)$ مقدَّر للمعلَّمة θ ، فعندئذٍ يُعرَّف مقدار تحيُّز المقدَّر T للمعلَّمة θ (وسنرمز له بـ $\vartheta(T, \theta)$) من خلال العلاقة الآتية:

$$\vartheta(T, \theta) := ET - \theta \quad [10,8]$$

(١٠, ٢, ١, ٢) تعريف (المقدَّر غير المنحاز Unbiased Estimator)

ليكن لدينا $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغيِّر عشوائي X ، ولنأخذ \mathcal{X}_n عينة من هذا المجتمع، فعندئذٍ يقال عن إحصاءة $T = g(\mathcal{X}_n)$ إنها **مقدَّر غير منحاز** للمعلَّمة θ إذا كانت العلاقة الآتية مُحَقَّقة:

$$\vartheta(T, \theta) = 0 \quad [10,9]$$

نلاحظ أنَّ العلاقة السابقة [10,9] تكافئ العلاقة $ET = \theta$ التي تستخدم غالباً في حل الأمثلة والتمارين.

(١٠, ٢, ١, ٣) أمثلة

١- ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغيِّر عشوائي X خاضع للتوزيع الطبيعي بمتوسط μ وانحراف معياري σ ، ولنأخذ $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ عينة من هذا المجتمع، فعندئذٍ:

أ- نجد أنَّ الإحصاءة $\bar{X} = g(\mathcal{X}_n)$ (مقدَّر متوسط المجتمع الطبيعي كما بيَّنا ذلك سابقاً) هي مُقدَّر غير منحاز لمتوسط هذا المجتمع، وذلك لأنَّه بحسب العلاقة [10,9] لدينا $E\bar{X} = \mu$.

ب- بفرض أنَّ:

$$\bar{X}_w = g(\mathcal{X}_n) = \alpha_1 X_1 + \alpha_2 X_2 + \dots + \alpha_n X_n$$

علماً أنَّ $\alpha_1, \alpha_2, \dots, \alpha_n$ و $0 < \alpha_n$ مع $\sum_{k=1}^n \alpha_k = 1$ (المتوسط الموزون للعينة) هو مقدَّر لمتوسط هذا المجتمع، فعندئذٍ نجد أنَّ هذه الإحصاءة \bar{X}_w هي مُقدَّر غير منحاز لمتوسط هذا المجتمع أيضاً، وذلك لأنَّه بسبب الاستقلال بين المتغيِّرات العشوائية X_1, X_2, \dots, X_n وتطابقها في التوزيع مع المتغيِّر العشوائي X سيكون لدينا ما يلي مُحَقَّقا:

$$E\bar{X}_w = E\left(\sum_{k=1}^n \alpha_k X_k\right) = \sum_{k=1}^n \alpha_k \cdot EX_k = \sum_{k=1}^n \alpha_k \cdot EX = (EX) \cdot \sum_{k=1}^n \alpha_k = EX = \mu$$

ج- إنَّ الإحصاءة \tilde{S}^2 هي مُقدَّر منحاز لتباين هذا المجتمع σ^2 ، وذلك لأنَّه لدينا من العلاقة [9-12-a] ما يلي:

$$E\tilde{S}^2 = \frac{n-1}{n} \sigma^2 \neq \sigma^2$$

ومقدَّار تحيُّزه $\vartheta(\tilde{S}^2, \sigma^2)$ يساوي:

$$g(\tilde{S}^2, \sigma^2) = E\tilde{S}^2 - \sigma^2 = -\frac{\sigma^2}{n}$$

د- إن الإحصاءة S^2 هي مُقدّر غير منحاز لتباين هذا المجتمع σ^2 ، وذلك لأن:

$$ES^2 = \frac{n}{n-1} E\tilde{S}^2 = \frac{n}{n-1} \frac{n-1}{n} \sigma^2 = \sigma^2$$

٢- ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X خاضع للتوزيع المنتظم المستمر على فترة $[a, b]$ مع $-\infty < a < b < \infty$ ، ولنأخذ \mathcal{X}_n عينة من هذا المجتمع، ولننظر إن كان \bar{X} و \tilde{S}^2 غير منحازين لـ μ متوسط و σ^2 تباين هذا المجتمع على الترتيب أم لا؟

في الواقع لدينا من استقلال المتغيرات العشوائية X_1, X_2, \dots, X_n ، وبسبب تطابقها في التوزيع مع المتغير العشوائي X ما يلي محققاً:

$$E\bar{X} = \frac{1}{n} E \sum_{k=1}^n X_k = \frac{1}{n} n \cdot EX = EX = \frac{a+b}{2} = \mu$$

وهذا يعني أن \bar{X} هو مُقدّر غير منحاز لمتوسط هذا المجتمع. كذلك للأسباب التي ذكرت سابقاً نفسها نجد ما يلي:

$$\begin{aligned} E\tilde{S}^2 &= \frac{1}{n} E \sum_{k=1}^n (X_k - \bar{X})^2 = EX^2 - E\bar{X}^2 \\ &= \frac{b^2 + ab + a^2}{3} - \frac{a^2 + 2ab + b^2}{4} = \frac{b^2 - 2ab + a^2}{12} = \frac{(b-a)^2}{12} = \text{var } X = \sigma^2 \end{aligned}$$

وهكذا نجد أن الإحصاءة \tilde{S}^2 هي مُقدّر غير منحاز لتباين هذا المجتمع في حين أننا نجد أن الإحصاءة S^2 هو مُقدّر منحاز لتباين هذا المجتمع؛ وذلك لأن:

$$ES^2 = \frac{n}{n-1} E\tilde{S}^2 = \frac{n}{n-1} \sigma^2 \neq \sigma^2$$

(٤، ١، ٢، ١٠) نتيجة

نستنتج من المثالين السابقين أن الإحصاءة التي تكون منصفة لمجتمع معين قد لا تكون كذلك بالنسبة إلى مجتمع آخر.

الآن لو أمعنا النظر في الفقرة (ج) من المثال ١ / في (٣، ١، ٢، ١٠)، فإننا نلاحظ أنه عندما يسعى حجم العينة n إلى اللانهاية فإن الإحصاءة \tilde{S}^2 تسعى لتصبح مُقدراً غير منحاز لـ σ^2 . إن الإحصاءات التي تتمتع بهذه الصفة يُقال عنها إنها تتمتع بالصفة التقاربية Asymptotic Property، والتعريف الآتي يقدم لنا هذا النوع من المقدرات.

(٥، ١، ٢، ١٠) تعريف (المقدّر غير المنحاز تقاربياً Asymptotic Unbiased Estimator)

ليكن لدينا $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X ، ولنأخذ \mathcal{X}_n عينة من هذا المجتمع، و $T = g(\mathcal{X}_n)$ مُقدراً للمعلمة θ ، فإذا كان:

$$\lim_{n \rightarrow \infty} E g(\mathcal{X}_n) = \theta \quad [10,10]$$

فعندئذ يُقال عن الإحصاءة T إنها مُقدّر غير منحاز تقاربياً للمعلمة θ .

(٦، ١، ٢، ١٠) أمثلة

١- بالعودة إلى المثال ١ / من (٣، ١، ٢، ١٠) نجد أن الإحصاءة \tilde{S}^2 هي مُقدّر غير منحاز تقاربياً لتباين المجتمع الطبيعي

المُعطى، وذلك لأن:

$$\lim_{n \rightarrow \infty} E\tilde{S}^2 = \lim_{n \rightarrow \infty} \frac{n-1}{n} ES^2 = \lim_{n \rightarrow \infty} \frac{n-1}{n} \sigma^2 = \sigma^2 \lim_{n \rightarrow \infty} \frac{n-1}{n} = \sigma^2$$

٢- بالعودة إلى المثال /٢/ من (١٠, ٢, ١, ٣) نجد أن الإحصاءة S^2 هي مُقدّر غير منحاز تقاربياً لتباين المجتمع المنتظم المستمر على الفترة (a, b) ، وذلك لأن:

$$\lim_{n \rightarrow \infty} ES^2 = \lim_{n \rightarrow \infty} \frac{n}{n-1} E\tilde{S}^2 = \lim_{n \rightarrow \infty} \frac{n(b-a)^2}{12(n-1)} = \lim_{n \rightarrow \infty} \frac{n}{n-1} \sigma^2 = \sigma^2 \lim_{n \rightarrow \infty} \frac{n}{n-1} = \sigma^2$$

(١٠, ٢, ٢) المقدرات المتسقة Consistent Estimators

لقد لوحظ أن تباين بعض المقدرات يصغر بـكبر حجم العينة بحيث إنه عندما يسعى حجم العينة إلى اللانهاية فإن تباين العينة سوف يسعى إلى الصفر. إن هذه الخاصية تُعرف باسم **شرط ماركوف** الذي تقدمه لنا الفقرة الآتية.

(١٠, ٢, ٢, ١) شرط ماركوف Markov Condition

ليكن لدينا $[\Omega, \mathcal{S}, P]$ مجتمعاً موصوفاً من خلال متغير عشوائي X ، ولناخذ \mathcal{X}_n عينة من هذا المجتمع، و $T = g(\mathcal{X}_n)$ إحصاءة معطاة. عندئذ يُقال إن T تحقق شرط ماركوف **إذا وفقط إذا** تحققت العلاقة الآتية:

$$\lim_{n \rightarrow \infty} \text{var } g(\mathcal{X}_n) = 0 \quad [10,11]$$

(١٠, ٢, ٢, ٢) مثال

ليكن لدينا $[\Omega, \mathcal{S}, P]$ مجتمعاً موصوفاً من خلال متغير عشوائي X له توزيع ما، ويملك عزوماً ابتدائية حتى المرتبة الرابعة على الأقل، وتباينه σ^2 ، ولتكن \mathcal{X}_n عينة من هذا المجتمع، ولناخذ الإحصاءة \tilde{S}^2 . عندئذ نجد أن \tilde{S}^2 يحقق شرط ماركوف، وذلك لأنه من العلاقة [9-13-a] لدينا:

$$\lim_{n \rightarrow \infty} \text{var } \tilde{S}^2 = \lim_{n \rightarrow \infty} \left(\frac{\mu^4 - \sigma^4}{n} - \frac{2(\mu^4 - 2\sigma^4)}{n^2} + \frac{\mu^4 - 3\sigma^4}{n^3} \right) = 0$$

توجد في الواقع مقدرات تتمتع بصفة عدم التحيز تقاربياً وتحقق شرط ماركوف أيضاً. إن هذا النوع من المقدرات يُقال عنها إنها تتمتع بـ **خاصية الاتساق** Consistency Property، والمقدّر الذي يجمع بين هاتين الصفتين يُدعى **مقدراً متسقاً**، والفقرة الآتية تقدم لنا تعريفه.

(١٠, ٢, ٢, ٣) تعريف (المقدّر المتسق Consistent Estimator)

ليكن لدينا $[\Omega, \mathcal{S}, P = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X ، ولتكن \mathcal{X}_n عينة من هذا المجتمع، فإذا كان $T = g(\mathcal{X}_n)$ مُقدراً للمعلمة θ ، فعندئذ يُقال عن الإحصاءة T إنها **مقدّر متسق** للمعلمة θ **إذا وفقط إذا** تحققت العلاقتين:

$$\text{a) } \lim_{n \rightarrow \infty} E(g(\mathcal{X}_n)) = \theta \quad \& \quad \text{b) } \lim_{n \rightarrow \infty} \text{var}(g(\mathcal{X}_n)) = 0$$

(١٠, ٢, ٢, ٤) مثال

ليكن لدينا $[\Omega, \mathcal{S}, P]$ مجتمعاً موصوفاً من خلال متغير عشوائي X له توزيع ما، ويملك عزوماً ابتدائية حتى المرتبة الرابعة على الأقل، وتباينه σ^2 ، ولتكن \mathcal{X}_n عينة من هذا المجتمع، فنجد من المثالين (١٠, ٢, ١, ٦) و (١٠, ٢, ٢, ٢) أن الإحصاءة \tilde{S}^2 هي مُقدّر غير منحاز تقاربياً لتباين هذا المجتمع، ويحقق شرط ماركوف أيضاً، ومن ثم الإحصاءة \tilde{S}^2 هي مُقدّر متسق للمعلمة σ^2 .

(١٠, ٢, ٢, ٥) ملاحظات

١- تجدر الملاحظة إلى أنه توجد نماذج أخرى من المقدرات المتسقة التي تُعرف بالمقدرات الضعيفة الاتساق والمقدرات القوية الاتساق، ولكن لن نخوض في هذه النماذج من المقدرات.

٢- إذا كان حجم العينة كبيراً، فإنَّ مقدرات الأرجحية العظمى للمعلمة التباين σ^2 ستكون متسقة أيضاً.

(١٠, ٢, ٣) المقدرات الكفوة Efficient Estimators

لقد لاحظنا سابقاً أنه من الممكن أن يكون لدينا أكثر من مُقدر غير منحاز للمعلمة مجتمع مُعطى، والسؤال الذي يُطرح هنا: أيُّ المقدرات غير المنحازة سنفضل؟

الفقرات الآتية تقدم مفاهيم تساعدنا في اختيار المقدر غير المنحاز الذي يعطينا معلومات أفضل حول معلمة المجتمع.

(١٠, ٢, ٣, ١) تعريف (المقدر الكفؤ Efficient Estimator)

ليكن $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X بدالة كثافة $f_X(x; \theta)$ قابلة للاشتقاق الجزئي بالنسبة إلى θ ، ولنأخذ \mathcal{X}_n عينة من هذا المجتمع، وبفرض أن $T = g(\mathcal{X}_n)$ مقدر غير منحاز للمعلمة θ ، فعندئذ يُقال عن الإحصاء T إنها مُقدر كفؤ للمعلمة θ إذا وفقط إذا تحققت العلاقة الآتية:

$$\text{var}T = \left[n \cdot \mathbf{E} \left(\frac{\partial \ln f_X(x; \theta)}{\partial \theta} \right)^2 \right]^{-1} \quad [10,12]$$

وأما النسبة المكونة للمقدار الآتي:

$$\text{ef}(T) := \frac{1}{\text{var}T} \left[n \cdot \mathbf{E} \left(\frac{\partial \ln f_X(x; \theta)}{\partial \theta} \right)^2 \right]^{-1} \quad [10,13]$$

فإنَّها تُدعى مقدار كفاءة المقدر T .

(١٠, ٢, ٣, ٢) تعريف (المقدر الأكفأ من مقدر آخر Estimator more efficient from another)

ليكن $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X ، ولتكن \mathcal{X}_n عينة من هذا المجتمع، وليكن $T_1 = g_1(\mathcal{X}_n)$ و $T_2 = g_2(\mathcal{X}_n)$ مقدرين غير منحازين للمعلمة θ ، فإذا كان $\text{var}T_2 \geq \text{var}T_1$ ، فعندئذ يُقال إنَّ المقدر T_1 أكفأ من المقدر T_2 .

تُدعى النسبة $\frac{\text{var}T_1}{\text{var}T_2}$ بـ الكفاءة النسبية Relative Efficiency لـ T_2 بالنسبة إلى T_1 ، وسنرمز لها بـ $\text{ef}(T_1, T_2)$ ، أي إنَّ:

$$\text{ef}(T_1, T_2) := \frac{\text{var}T_1}{\text{var}T_2} \quad [10,14]$$

(١٠, ٢, ٣, ٣) تعريف (المقدر الأعلى كفاءة Highest Efficient Estimator):

ليكن $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X ، ولنأخذ \mathcal{X}_n عينة من هذا المجتمع، ولنفترض أن \mathcal{T} هي أسرة كل المقدرات غير المنحازة للمعلمة θ ، فإذا وجد مقدر $T \in \mathcal{T}$ بحيث تكون المتباينة الآتية محققة:

$$\text{var}T \leq \text{var}T^* \quad ; \quad \forall T^* \in \mathcal{T} \quad [10,15]$$

فعندئذ يُقال عن T إنه المقدر الأعلى كفاءة للمعلمة θ (أو الأكفأ أو أفضل مقدر خطي للمعلمة θ).

من المتباينات المهمة في مجال دراسة المقدرات النقطية ما يُعرف باسم **متباينة راو-كرامر** التي تقدمها المبرهنة الآتية (سنقبلها دون برهان).

(١٠, ٢, ٤) مبرهنة (متباينة راو-كرامر (Rao-Cramer Inequality))

ليكن $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي نظامي X بالنسبة إلى $\Theta \ni \theta$ ، ولنأخذ عينة من هذا المجتمع، و $T = g(\mathcal{X}_n)$ مقدراً نظامياً بالنسبة إلى $\Theta \ni \theta$ ، فعندئذ إذا كانت Θ_θ مجموعة مفتوحة، فإنه ستكون المتباينة الآتية محققة:

$$\text{var} T \geq \left[1 + \left(\frac{d \vartheta(T, \theta)}{d \theta} \right)^2 \right] \cdot \left[n \cdot \mathbf{E} \left(\frac{\partial \ln f_X(x; \theta)}{\partial \theta} \right)^2 \right]^{-1} \quad [10,16]$$

وهذه المتباينة تُعرف باسم **متباينة راو-كرامر** نسبة إلى الإحصائي البريطاني (هندي الأصل) **راو** Calyampudi Radhakrishna Rao (1920) والرياضياتي الإحصائي السويدي **كرامر** Harald Cramér (1893-1985).

إن الطرف الأيمن من المتباينة السابقة يُدعى **الحد الأدنى لمتباينة راو-كرامر**، وإذا حققت الإحصاءة T علاقة المساواة في هذه المتباينة، فعندئذ يُقال إن الإحصاءة T بلغت الحد الأدنى لمتباينة راو-كرامر.

(١٠, ٢, ٤, ١) نتائج

١- إذا كان T مقدراً غير منحاز للمعلمة θ ، فعندئذ بحسب تعريف المقدّر المنصف سيكون لدينا $\vartheta(T, \theta) = 0$ ، ومن ثم يصبح لمتباينة راو كرامر العرض الآتي:

$$\text{var} T \geq \left[n \cdot \mathbf{E} \left(\frac{\partial \ln f_X(x; \theta)}{\partial \theta} \right)^2 \right]^{-1} \quad [10,17]$$

ومنه ينتج أن المقدّر الكفؤ للمعلمة θ هو ذلك المقدّر غير المنحاز الذي يُحقق علاقة المساواة في متباينة راو-كرامر (أي يبلغ الحد الأدنى لمتباينة راو-كرامر).

٢- إذا كان T مقدراً كفواً للمعلمة θ ، فعندئذ سيكون لدينا ما يلي مُحققاً:

$$\text{var} T = \left[\mathbf{I}_{\mathcal{X}_n}(\theta) \right]^{-1} \quad [10,18]$$

علماً أن $\mathbf{I}_{\mathcal{X}_n}(\theta)$ هي كمية معلومات فيشر التي تقدمها العينة \mathcal{X}_n حول المعلمة θ .

(١٠, ٢, ٤, ٢) مثال

١- ليكن لدينا $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X خاضع لتوزيع برنولي بمعلمة $0 < p < 1$ ، و \mathcal{X}_n عينة من هذا المجتمع، وبفرض أن $T = \sum_{k=1}^n \alpha X_k$ إحصاءة مُعطاة، ولنقم بما يلي:

أ- حساب قيمة الثابت α بحيث يصبح الإحصاءة T مقدراً غير منحاز للمعلمة p .

ب- تبيان إن كان T مقدراً كفواً للمعلمة p أم لا.

ج- تبيان إن كان T هو المقدّر الأكفأ للمعلمة p أم لا.

الحل: من أجل الطلب:

أ- لكي يكون T مقدراً غير منحاز للمعلمة p يجب أن يكون $ET = p$ ، ومن ثم نجد الآتي:

$$p = ET = \alpha \sum_{k=1}^n EX_k = \alpha n EX = \alpha n p$$

والتي ينتج عنها أنه حتى تصبح الإحصاءة T مقدراً غير منحاز للمعلمة p يجب أن تكون قيمة الثابت α تساوي $\frac{1}{n}$ ، ومن ثم يجب أن يكون $T = \bar{\pi}$.

ب- من أجل أي $x \in \{0,1\}$ لدينا $f_X(x; p) = p^x (1-p)^{1-x}$ ، وبأخذ لوغاريتم الطرفين لهذه العلاقة ينتج لدينا:

$$\ln f_X(x; p) = x \cdot \ln p + (1-x) \cdot \ln(1-p)$$

وبالاشتقاق الجزئي للعلاقة الأخيرة بالنسبة إلى p نجد الآتي:

$$\frac{\partial \ln f_X(x; p)}{\partial p} = \frac{x}{p} - \frac{1-x}{1-p}$$

وبالاشتقاق الجزئي للعلاقة الأخيرة بالنسبة إلى p مرة أخرى ينتج لدينا ما يلي:

$$\frac{\partial^2 \ln f_X(x; p)}{\partial p^2} = \frac{-x}{p^2} - \frac{1-x}{(1-p)^2}$$

ومن ثم يصبح لدينا:

$$E \left(\frac{-\partial^2 \ln f_X(x; p)}{\partial p^2} \right) = \sum_{x=0}^1 \frac{-\partial^2 \ln f_X(x; p)}{\partial p^2} f_X(x; p) = \frac{1}{p(1-p)}$$

ومنه تكون كمية المعلومات التي تقدمها العينة \mathcal{X}_n حول المعلمة p هي:

$$\left[n \cdot E \left(\frac{\partial \ln f_X(x; p)}{\partial p} \right)^2 \right]^{-1} = \frac{p(1-p)}{n} \quad (1)$$

وهكذا نجد أن المقدّر $\bar{\pi}$ يحقق علاقة المساواة في متباينة راو-كرامر، ومن ثم $\bar{\pi}$ هو مقدّر كفؤ للمعلمة p .

ج- الآن لتبيان إن كان $\bar{\pi}$ هو المقدّر الأكفأ للمعلمة p أم لا سنقوم بحساب $\text{var} T$ ، فنجد أن:

$$\text{var} T = \text{var} \bar{X} = \frac{1}{n^2} \sum_{k=1}^n \text{var} X_k = \frac{1}{n^2} n \cdot \text{var} X = \frac{p(1-p)}{n} \quad (2)$$

والآن من العلاقتين (1) و (2) نستنتج أن:

$$\text{var} T = \left[n \cdot E \left(\frac{\partial \ln f_X(x; p)}{\partial p} \right)^2 \right]^{-1}$$

وهذا يعني أن الإحصاء $\bar{\pi}$ هو المقدّر الأكفأ للمعلمة p أيضاً.

تعطينا المبرهنة الآتية (التي سنقبلها دون برهان) الشرط اللازم والكافي حتى يبلغ مقدّر معلمة مجتمع إحصائي الحد الأدنى للمتباينة راو-كرامر.

(١٠, ٢, ٤, ٣) مبرهنة

ليكن لدينا $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X ، ولنأخذ \mathcal{X}_n عينة من هذا المجتمع، و $T = g(\mathcal{X}_n)$ مقدراً غير منحاز للمعلمة θ بأقل تباين، فعندئذ يبلغ T الحد الأدنى لتباينة راو-كرامر إذا وفقط إذا كانت الدالة $f_X(x; \theta)$ أسية، أي إنه يمكن كتابة الدالة $f_X(x; \theta)$ على النحو الآتي:

$$f_X(x; \theta) = \exp [s(\theta) + h(x) + u(\theta) \cdot v(x)] \quad [10,17]$$

وتكون حينئذ الإحصاءة $U = \frac{1}{n} \sum_{k=1}^n \ln X_k$ هي مُقدّر غير منحاز بأقل تباين للمعلمة $\frac{-s'(\theta)}{u'(\theta)}$ ، علماً أن الاشتقاق هنا يتم بالنسبة إلى المعلمة θ .

(١٠, ٢, ٤, ٤) مثال

ليكن $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X بدالة كثافة احتمالية $f_X(x; \theta)$ معطاة من خلال العلاقة:

$$f_X(x; \theta) = \theta \cdot x^{\theta-1} \mathbf{I}_{(0,1)}(x) \quad ; \forall x \in \mathbb{R}$$

ولنقم بإيجاد مُقدّر غير منحاز بأقل تباين للمعلمة $\frac{1}{\theta}$ مستخدمين في ذلك الحد الأدنى لتباينة راو-كرامر.

من أجل ذلك نلاحظ أنه يمكننا كتابة الدالة $f_X(x; \theta)$ على النحو الآتي:

$$f_X(x; \theta) = \exp [\ln \theta - \ln x + \theta \ln x] \cdot \mathbf{I}_{(0,1)}(x)$$

وكما هو واضح فإن $f_X(x; \theta)$ نموذج دالة أسية، حيث لدينا:

$$s(\theta) = \ln \theta \quad \& \quad h(x) = -\ln x \quad \& \quad u(\theta) = \theta \quad \& \quad v(x) = \ln x$$

ومن ثم بحسب المبرهنة السابقة تكون الإحصاءة الآتي:

$$T = \frac{-1}{n} \sum_{k=1}^n \ln X_k = \left(\ln \prod_{k=1}^n X_k \right)^{-\frac{1}{n}}$$

هي مُقدّر غير منحاز بأقل تباين للمعلمة $\frac{-s'(\theta)}{u'(\theta)} = \frac{1}{\theta}$.

(١٠, ٣) فترات الثقة

Confidence Intervals

لقد بينا في دراستنا للمقدرات النقطية متى نفضل مقدراً على آخر بخصوص معلمة مجتمع معتمدين في ذلك على عينة مسحوبة من المجتمع الذي قيد الدراسة. إن عملية التفضيل لهذا المقدّر على ذاك كانت مبنية على بعض الخصائص التي يتمتع بها المقدّر، ومن ثم نكون على قدر ما من الثقة من أن قيمة هذا المقدّر قريبة من قيمة المعلمة المفترضة، ولكن القيمة التي تنتج عن هذا المقدّر كعدد مجرد لا تعطينا القيمة الاحتمالية التي تدلّ على مساواة قيمة هذا المقدّر لقيمة المعلمة المقدّرة. بمعنى آخر، ما هو احتمال أن تكون قيمة هذا المقدّر الذي تمّ تعيينه مساوية أو قريبة من قيمة هذه المعلمة المقدّرة؟

(١٠, ٣, ١) مفهوم فترة الثقة لمعلمة مجتمع إحصائي Concept of Confidence Interval of Population

من أجل توضيح ذلك سنأخذ $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X ، ولنسحب عينة \mathcal{X}_n من هذا المجتمع، ولنفترض أن $T = g(\mathcal{X}_n)$ مُقدّر للمعلمة θ ، فعندئذ الإجابة على السؤال السابق تكمن في تعيين قيمة

احتمال الحادث $\{\omega \in \Omega ; |T(\omega) - \theta| < \varepsilon\}$ علماً أن $0 < \varepsilon$ مُعطى. بكلمات أخرى، بفرض أن $0 \leq \alpha \leq 1$ عدد حقيقي مُعطى، فما هي قيمة $0 < \varepsilon$ التي من أجلها تكون العلاقة الآتية محققة:

$$P(|T - \theta| < \varepsilon) = 1 - \alpha \quad [10,18-a]$$

وهنا نلاحظ أنه كلما كانت قيمة α و ε صغيرة، دل ذلك على أن قيمة المقدّر T ستكون قريبة من قيمة المعلمة المقدّرة θ باحتمال كبير. إن العلاقة الأخيرة تعطينا العلاقة الآتية:

$$P(T - \varepsilon < \theta < T + \varepsilon) = 1 - \alpha \quad [10,18-b]$$

ومن ثمّ تؤول المسألة إلى إيجاد مُقدّرين $T_1 = T - \varepsilon$ و $T_2 = T + \varepsilon$ بحيث يكون احتمال أن تقع قيمة المعلمة θ في فترة مفتوحة (t_1, t_2) يساوي $1 - \alpha$ ، علماً أن t_1 و t_2 هما قيمة T_1 و T_2 على الترتيب، وفي هذه الحالة تُدعى الإحصاءة T_1 **حد الثقة الأدنى** Lower Confidence Limit للمعلمة θ في حين تُدعى الإحصاءة T_2 **حد الثقة الأعلى** Upper Confidence Limit للمعلمة θ .

(١٠, ٣, ١, ١) تعريف (فترة الثقة لمعلمة مجتمع Confidence Interval of Population)

ليكن $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X ، ولتكن \mathcal{X}_n عينة مسحوبة من هذا المجتمع، وليكن $T_1 = g_1(\mathcal{X}_n)$ و $T_2 = g_2(\mathcal{X}_n)$ إحصائيتين مُعطين، و $0 \leq \alpha \leq 1$ ، فعندئذ إذا كان X **مستمراً** فإن العلاقة الآتية:

$$P(T_1 < \theta < T_2) = 1 - \alpha \quad [10,19]$$

تُعرف لنا **100 (1- α) % فترة ثقة** للمعلمة θ ، وحينئذ المقدار $(1 - \alpha)$ يُدعى **مستوى الثقة** (أو **معامل الثقة**) Confidence Level.

(١٠, ٣, ١, ٢) ملاحظات

١- في دراستنا المقبلة سيتم التركيز على المجتمعات الطبيعية والبرنولية، أي إننا سنأخذ X متغيراً عشوائياً طبيعياً (أو طبيعياً على وجه التقريب) أو برنولياً، ومن أجل المجتمعات البرنولية سنأخذ عينات كبيرة بقدر كاف بحيث يمكن تطبيق مبرهنة النهاية المركزية لـ موافير-لابلاس.

٢- من العلاقة [10-19] ومن أجل $\alpha_1 + \alpha_2 = \alpha$ يمكننا أن نكتب العلاقتين الآتيتين:

$$P(T_1 \geq \theta) = \alpha_1 \quad \& \quad P(T_2 \leq \theta) = \alpha_2$$

وفي الحالة الخاصة عندما يكون $\alpha_1 = \alpha_2 = \frac{\alpha}{2}$ فإنه يُرهن على أن طول فترة الثقة لـ θ سيكون أصغرياً (أي نحصل على أقصر طول فترة ثقة لـ θ)، ولذلك سينصب اهتمامنا فيما يأتي على إعطاء فترات الثقة للمعلمة θ (أو لإحدى مُركّبات θ إذا كان θ متجهاً من \mathbb{R}^k) من أجل الحالة التي يكون فيها $\alpha_1 = \alpha_2 = \frac{\alpha}{2}$ ، وذلك دون الخوض في كيفية استنتاج هذه الفترات، حيث يمكن للقارئ أن يستنتج بعضها بسهولة من خلال تطبيق العلاقة [10-18-b] ومن ثمّ حساب قيمة ε .

٣- إذا استطعنا تعيين $100 (1 - \alpha) \%$ فترة ثقة للمعلمة θ وفقاً للعلاقة [10-18-b] فعندئذ يمكننا تعيين $100 (1 - \alpha) \%$ فترة ثقة لآية دالة مطردة $g(\theta)$ من خلال العلاقة الآتية:

$$P(g(T_1) < g(\theta) < g(T_2)) = 1 - \alpha \quad [10,20]$$

فيما يلي سنقوم بتعيين فترات الثقة في حال أنه لدينا مجتمع وحيد، وبعد ذلك في حال لدينا مجتمعين مستقلين مع الأخذ بالملاحظات / ١٠, ٣, ١, ٢ .

(١٠, ٣, ٢) فترات الثقة لمعلمتي مجتمع طبيعي

سنفترض على مدى هذه الفقرة أنه لدينا $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X خاضع للتوزيع الطبيعي بمتوسط μ وانحراف معياري σ ، وأن $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ عينة من هذا المجتمع بمتوسط \bar{X} وانحراف معياري S . تحت هذه الافتراضات سنقوم بتعيين فترة الثقة لـ μ في كل من الحالتين الخاصتين الآتيتين:

أ- إذا كان الانحراف المعياري σ للمجتمع معلوماً.

ب- إذا كان الانحراف المعياري σ للمجتمع مجهولاً.

وبعد ذلك سننتقل إلى تعيين فترة الثقة لـ σ^2 (تباين هذا المجتمع). إن المبرهنة الآتية (التي سنقبلها دون برهان) تقدم لنا فترات الثقة لمتوسط مجتمع طبيعي.

(١٠, ٣, ٢, ١) مبرهنة

تحت الفرضيات المذكورة آنفاً يكون لدينا ما يلي:

١- إذا كان الانحراف المعياري للمجتمع معلوماً مع $\sigma = \sigma_0$ ، فعندئذ تُعطى $\% (1-\alpha) 100$ فترة ثقة لـ μ (متوسط هذا المجتمع) من خلال الفترة الآتية:

$$\left(\bar{X} - \frac{\sigma_0}{\sqrt{n}} \mathcal{Z}_{1-\frac{\alpha}{2}}, \bar{X} + \frac{\sigma_0}{\sqrt{n}} \mathcal{Z}_{1-\frac{\alpha}{2}} \right) \quad [10,21-a]$$

علماً أن \mathcal{Z}_k هي تلك النقطة على المحور الحقيقي التي يقع على يسارها وتحت منحنى الكثافة للتوزيع الطبيعي المعياري مساحة مقدارها يساوي k .

٢- إذا كان الانحراف المعياري للمجتمع σ مجهولاً، فعندئذ تُعطى $\% (1-\alpha) 100$ فترة ثقة لـ μ من خلال الفترة الآتية:

$$\left(\bar{X} - \frac{s}{\sqrt{n}} t_{1-\frac{\alpha}{2}}^{[n-1]}, \bar{X} + \frac{s}{\sqrt{n}} t_{1-\frac{\alpha}{2}}^{[n-1]} \right) \quad [10,21-b]$$

علماً أن $t_k^{[n]}$ هي تلك النقطة على المحور الحقيقي التي يقع على يسارها وتحت منحنى الكثافة لتوزيع ستودنت (أو توزيع t) ذي الـ n درجة حرية مساحة قدرها k ، وأما s فهي قيمة الإحصاء S .

(١٠, ٣, ٢, ٢) ملاحظات

١- في الحالة الخاصة عندما يكون σ مجهولاً وحجم العينة n كبيراً (أي إن $32 \leq n$) فإن بعض المراجع تقوم باستخدام الفترة الآتية:

$$\left(\bar{X} - \frac{s}{\sqrt{n}} \mathcal{Z}_{1-\frac{\alpha}{2}}, \bar{X} + \frac{s}{\sqrt{n}} \mathcal{Z}_{1-\frac{\alpha}{2}} \right) \quad [10,21-c]$$

على أنها $\% (1-\alpha) 100$ فترة ثقة لـ μ بدلاً من الفترة [10-21-b]، ويبررون ذلك من خلال كون الفوارق الناتجة عن استخدام توزيع ستودنت والتوزيع الطبيعي المعياري من أجل قيم $32 \leq n$ صغيرة، وتزداد صغراً كلما كبر حجم العينة لدرجة أنه يمكن معها النظر إلى هذه الفوارق كمقادير مهملة (أمعن النظر في الجدولين الخاصين بالتوزيعين المذكورين في نهاية الكتاب)، ويضاف إلى ما سبق أن الكثير من جداول توزيع ستودنت تقدم قيم $t_k^{[n]}$ من أجل بعض القيم لـ n عندما تصبح $30 < n$ حيث تقدم تلك القيم على قفزات بتزايدات مختلفة 5 أو 10 أو ...، ولكن في كتابنا هذا لن نعمل بهذه الملاحظة ونستخدم كلاً حسب توزيعه الأصل، والجدول الذي سيقدم يتضمن قيم n بدءاً من 1 وحتى 100 بشكل متتال.

٢- إن الفترة المُعطاة من خلال [10,21-a] صحيحة ما دام المجتمع الذي قيد الدراسة غير محدود، أو أن المعاينة تتم مع الإعادة من أجل المجتمعات المحدودة، وأما إذا كان هذا المجتمع محدوداً وحجمه N ، وكانت المعاينة تتم دون إعادة، فعندئذ يُفضل استخدام الفترة الآتية عوضاً عن الفترة المقدمة في [10,21-a]:

$$\left(\bar{x} - \frac{\sigma_o}{\sqrt{n}} \sqrt{\frac{N-n}{N-1}} \cdot \mathcal{Z}_{1-\frac{\alpha}{2}}, \bar{x} + \frac{\sigma_o}{\sqrt{n}} \sqrt{\frac{N-n}{N-1}} \cdot \mathcal{Z}_{1-\frac{\alpha}{2}} \right) \quad [10,21-d]$$

وتكون هذه الفترة أكثر دقةً عندما يكون حجم العينة $n < 0.05 N$.

٣- فيما بعد وعندما نذكر عبارة "الفترة [?, ?]" إننا نقصد بذلك الفترة ذات الرقم [?, ?]. كذلك وعلى سبيل التذكير، عندما لا يُذكر شيء حول حجم المجتمع المدروس، فإننا نعني بذلك أن حجم المجتمع غير محدود، وكذلك عندما لا يُذكر شيء حول نوع عملية المعاينة، فإننا يُقصد بذلك أن المعاينة تتم مع الإعادة ما دام المجتمع محدوداً (ذلك أنه في حال المجتمعات غير المحدودة، لا أهمية تذكر لنوع عملية المعاينة، سواء أكانت هذه العملية تتم مع الإعادة أم بدون إعادة).

(١٠, ٣, ٢, ٣) نتائج

من المبرهنة (١٠, ٣, ٢, ١) والملاحظات (١٠, ٣, ٢, ٢) السابقتين نحصل على النتائج الآتية:

١- إذا كان الانحراف المعياري للمجتمع معلوماً $\sigma = \sigma_o$ ، فعندئذ:

أ- إذا كان حجم المجتمع غير محدود فإن تقديرنا لمتوسط المجتمع μ بالقيمة \bar{x} (قيمة \bar{X}) وعند مستوى من الثقة قدره $1-\alpha$ سيترتب عليه خطأ أعظمي (سنرمز له بـ er) يساوي:

$$er = \pm \frac{\sigma_o}{\sqrt{n}} \cdot \mathcal{Z}_{1-\frac{\alpha}{2}} \quad [10,22-a]$$

ومن أجل قيمة مُعطاة للخطأ $er = er_o$ يُقدَّر حجم العينة التي يجب سحبها بحيث لا يتجاوز الخطأ المرتكب في تقديرنا لـ μ بالقيمة \bar{x} أكثر من er_o بوساطة المتباينة الآتية:

$$n \geq \left(\frac{\sigma_o}{er_o} \cdot \mathcal{Z}_{1-\frac{\alpha}{2}} \right)^2 \quad [10,22-b]$$

ب- إذا كان حجم المجتمع محدوداً ويساوي N ، فإن تقديرنا لمتوسط المجتمع μ بالقيمة \bar{x} وعند مستوى من الثقة قدره $1-\alpha$ سيترتب عليه خطأ أعظمي (سنرمز له بـ er أيضاً) يساوي:

$$er = \pm \frac{\sigma_o}{\sqrt{n}} \cdot \sqrt{\frac{N-n}{N-1}} \cdot \mathcal{Z}_{1-\frac{\alpha}{2}} \quad [10,23-a]$$

ومن أجل قيمة مُعطاة للخطأ er يُقدَّر حجم العينة التي يجب سحبها بحيث لا يتجاوز الخطأ المرتكب في تقديرنا لـ μ بالقيمة \bar{x} أكثر من er_o بوساطة المتباينة الآتية:

$$n \geq N \cdot \sigma_o^2 \cdot \mathcal{Z}_{1-\frac{\alpha}{2}}^2 \cdot \left[(N-1) er_o^2 + \sigma_o^2 \cdot \mathcal{Z}_{1-\frac{\alpha}{2}}^2 \right]^{-1} \quad [10,23-b]$$

إن الخطأ er (وفي كلا الحالتين) يُدعى الخطأ المحتمل، وذلك لأنه يكون مُحققاً باحتمال معلوم يساوي $1-\alpha$.

٢- إذا كان الانحراف المعياري للمجتمع مجهولاً $\sigma = ?$ ، فعندئذ تقديرنا لمتوسط المجتمع μ بالقيمة \bar{x} وعند مستوى من الثقة قدره $1 - \alpha$ سيترب عليه خطأ أعظمي er مقداره يساوي:

$$er = \pm \frac{s}{\sqrt{n}} \cdot t_{1-\frac{\alpha}{2}}^{[n-1]} \quad [10,24]$$

ومن أجل قيمة er_o معطاة للخطأ، فإنه يُقدّر حجم العينة التي يجب سحبها بحيث لا يتجاوز الخطأ المرتكب في تقديرنا ل μ بالقيمة \bar{x} أكثر من er_o بوساطة المتباينة الآتية:

$$n \geq \left(\frac{s}{er_o} \cdot t_{1-\frac{\alpha}{2}}^{[n-1]} \right)^2 \quad [10,25]$$

تقدم لنا المبرهنة الآتية (التي سنقبلها دون برهان) فترة الثقة ل σ^2 (تباين مجتمع طبيعي).

(١٠, ٣, ٢, ٤) مبرهنة

تحت الفرضيات المذكورة سابقاً في أولاً من (١٠, ٣, ٢) تُعطى $100(1-\alpha)\%$ فترة ثقة ل σ^2 من خلال الفترة الآتية:

$$\left((n-1) s^2 / \chi_{1-\frac{\alpha}{2}}^{[n-1]}, (n-1) s^2 / \chi_{\frac{\alpha}{2}}^{[n-1]} \right) \quad [10,26]$$

علماً أن $\chi_k^{[m]}$ هي تلك النقطة على المحور الحقيقي التي يقع على يسارها وتحت منحنى دالة الكثافة الاحتمالية لتوزيع كاي مربع ذي الـ m درجة حرية مساحة قدرها k .

(١٠, ٣, ٢, ٥) ملاحظة

إن معظم جداول توزيع كاي مربع تُعطى من أجل بعض القيم لـ n ، وعندما تصبح قيمة n أكبر 25 أو 30 فإنها تقدم بتزايدات 5 أو 10 أو أكثر من ذلك، ولذلك فإنه من أجل قيم n غير الموجودة في هذه الجداول يمكن استخدام جدول التوزيع الطبيعي عوضاً عن جدول توزيع كاي مربع من خلال حساب $\chi_{\alpha}^{[n]}$ وفقاً للعلاقة الآتية:

$$\chi_{\alpha}^{[n]} = \frac{1}{2} \left(\chi_{\alpha} + \sqrt{2n-1} \right)^2 \quad [10,27]$$

حيث نحصل على قيمة تقريبية مقبولة في مثل هذه الحالات.

(١٠, ٣, ٢, ٦) أمثلة

١- زعم أحد المتاجر أن متوسط أرباحه اليومية على مرور أيام السنة يساوي 1000 وحدة نقدية بانحراف معياري قدره 100 وحدة نقدية وذلك عند مستوى من الثقة قدره 95%. للتأكد من صحة زعم صاحب هذا المتجر قمنا بحساب الأرباح اليومية ل 25 يوماً سُجبت عشوائياً من سجل مبيعات المتجر لسنة كاملة، فوجدنا المعطيات الآتية:

الجدول (١٠, ١)

اليوم	المبلغ	اليوم	المبلغ	اليوم	المبلغ	اليوم	المبلغ
1	900	8	1000	15	950	22	950
2	1000	9	850	16	1200	23	1010
3	950	10	800	17	1000	24	1000
4	1300	11	1000	18	1100	25	850
5	1000	12	950	19	1000		
6	1010	13	1000	20	1010		
7	1010	14	1100	21	800		

ومن هذه البيانات نجد أن $\bar{x} = 989.6$ و $s = 110.434$ ، ومن ثم بفرض أن الأرباح اليومية للمتجر تخضع للتوزيع الطبيعي على وجه التقريب بمتوسط μ وانحراف معياري σ ، فعندئذ:

أ- إذا افترضنا أن قيمة الانحراف المعياري التي قدمها المتجر موثوق بها (أي إن $\sigma_o = \sigma = 100$ معلومة) فإن $100(1-\alpha)\%$ فترة ثقة لمتوسط أرباح المتجر تُعطى من خلال الفترة $[10, 21-d]$ أن حجم المجتمع الذي سُحبت منه محدوداً ويساوي $N = 365$ يوماً، حيث لدينا $1-\alpha = 0.95$ و $n = 25$ وكذلك باستخدام جدول التوزيع الطبيعي نجد:

$$z_{1-\frac{\alpha}{2}} = z_{1-\frac{0.05}{2}} = z_{0.975} = 1.96$$

وبعد التعويض في الفترة $[10-21-d]$ كلاً بما يساويه نجد أن 95% فترة ثقة لـ μ متوسط أرباح المتجر هي $(952.99, 1026.22)$ ، وبما أن القيمة (1000 وحدة نقدية) التي قدمها صاحب المتجر تقع في فترة الثقة الموافقة لهذه الحالة، فإننا سنقبل بادعاء صاحب المتجر حول متوسط أرباحه اليومية عند مستوى الثقة 95% ، وفي هذه الحالة تكون قيمة الخطأ المرتكب في تقديرنا لمتوسط أرباح المتجر بقيمة $\bar{x} = 989.6$ في حال كانت قيمة الانحراف المعياري المقدمة معلومة تساوي:

$$er = \pm \frac{\sigma_o}{\sqrt{n}} \sqrt{\frac{N-n}{N-1}} \cdot z_{1-\frac{\alpha}{2}} = \pm \frac{100}{\sqrt{25}} \sqrt{\frac{365-25}{365-1}} \cdot 1.96 = \pm 36.62$$

ومن أجل حساب حجم العينة التي يجب سحبها (عدد الأيام التي يجب حساب متوسط أرباحها) بحيث إن الخطأ المرتكب في تقديرنا لـ μ بالقيمة $\bar{x} = 989.6$ لا يتجاوز $er_o = 35$ وحدة نقدية لدينا:

$$n \geq \frac{N \cdot \sigma_o^2 \cdot z_{1-\frac{\alpha}{2}}^2}{(N-1) er_o^2 + \sigma_o^2 \cdot z_{1-\frac{\alpha}{2}}^2} = \frac{365 (100)(1.96)^2}{(364)(35)^2 + (100)^2 (1.96)^2} = 28.95$$

وبما أن حجم العينة n يجب أن يكون عدداً صحيحاً، فإنه علينا أخذ $n = 29$ على الأقل.

أما إذا افترضنا أن حجم المجتمع غير محدود (بمعنى أن المتجر يعمل منذ زمن بعيد جداً وأن العينة التي سُحبت كانت من دفاتر سجلاته السابقة منذ نشأة المتجر)، فعندئذ نعين 95% فترة ثقة لـ μ متوسط أرباح من خلال الفترة $[10-21-a]$ ، وبعد التعويض وتنفيذ الحسابات المطلوبة نجدها تساوي:

$$\left(\bar{x} - \frac{\sigma_o}{\sqrt{n}} z_{1-\frac{\alpha}{2}}, \bar{x} + \frac{\sigma_o}{\sqrt{n}} z_{1-\frac{\alpha}{2}} \right) = \left(989.6 - \frac{100}{\sqrt{25}} 1.96, 989.6 + \frac{100}{\sqrt{25}} 1.96 \right) = (950.40, 1028.80)$$

ومن ثم لا يطرأ أي تغيير على القرار الذي اتخذناه سابقاً عند المستوى الثقة 95% ، وفي هذه الحالة تكون قيمة الخطأ المرتكب في تقديرنا لمتوسط أرباح المتجر بقيمة $\bar{x} = 989.6$ في حال كانت قيمة الانحراف المعياري المقدمة معلومة تساوي:

$$er = \pm \frac{\sigma_o}{\sqrt{n}} \cdot z_{1-\frac{\alpha}{2}} = \pm \frac{100}{\sqrt{25}} \cdot 1.96 = \pm 39.20$$

وأما إذا أردنا حساب حجم العينة التي يجب سحبها بحيث لا يتجاوز الخطأ المرتكب في تقديرنا لـ μ بالقيمة $\bar{x} = 989.6$ بأكثر من 35 وحدة نقدية، فإننا نجده يساوي:

$$n \geq \left(\frac{\sigma_o}{er_o} \cdot z_{1-\frac{\alpha}{2}} \right)^2 = \left(\frac{100}{35} \cdot 1.96 \right)^2 = 31.36$$

وهذا يعني أنه في هذه الحالة يجب أخذ $n = 32$ على الأقل.

ب- إذا افترضنا أن قيمة الانحراف المعياري التي قدمها المتجر غير موثوق بها (أي إن $\sigma = ?$ **مجهولة**) فإن $100(1-\alpha)\%$ فترة ثقة لمتوسط أرباح المتجر تُعطى من خلال الفترة $[10,21-b]$ ، وبما أنه لدينا $n = 25$ و $1-\alpha = 0.95$ و $t_{\frac{1-\alpha}{2}}^{[n-1]} = t_{0.975}^{[24]} = 2.064$ (من جدول توزيع ستودنت)، فإنه سيكون لدينا 95% فترة ثقة لـ μ متوسط أرباح المتجر لها العرض الآتي:

$$\left(\bar{x} - \frac{s}{\sqrt{n}} t_{\frac{1-\alpha}{2}}^{[n-1]}, \bar{x} + \frac{s}{\sqrt{n}} t_{\frac{1-\alpha}{2}}^{[n-1]} \right) = \left(989.6 - \frac{110.434}{\sqrt{25}} \cdot 2.064, 989.6 + \frac{110.434}{\sqrt{25}} \cdot 2.064 \right) \\ = (944.01, 1035.19)$$

وفي هذه الحالة نلاحظ أن القرار الذي اتخذناه سابقاً يبقى صحيحاً عند المستوى الثقة 95% أيضاً، وتكون قيمة الخطأ المرتكب في تقديرنا لمتوسط أرباح المتجر بقيمة $\bar{x} = 989.6$ في حال كانت قيمة الانحراف المعياري المقدّمة مجهولة تساوي:

$$er = \pm \frac{s}{\sqrt{n}} t_{\frac{1-\alpha}{2}}^{[n-1]} = \pm \frac{110.434}{\sqrt{25}} \cdot 2.064 = \pm 45.59$$

وأما إذا أردنا حساب حجم العينة التي يجب سحبها (عدد الأيام التي يجب حسابها متوسط أرباحها) بحيث لا يتجاوز الخطأ المرتكب في تقديرنا لـ μ بـ $\bar{x} = 989.6$ قيمة معلومة تساوي $er_o = 35$ وحدة نقدية فإننا نجده يساوي:

$$n \geq \left(\frac{s}{er_o} \cdot t_{\frac{1-\alpha}{2}}^{[n-1]} \right)^2 = \left(\frac{110.43}{35} \cdot 2.064 \right)^2 = 42.41$$

وهذا يعني أنه يجب أخذ $n = 43$ على الأقل في هذه الحالة.

هـ - أخيراً لنقم بتعيين 95% فترة ثقة لـ σ^2 تبين مجتمع الأرباح اليومية لمتجر، حيث نعلم أن $100(1-\alpha)\%$ فترة ثقة لـ σ^2 تُعطى من خلال الفترة $[10-26]$ ، حيث لدينا:

$$\chi_{\frac{1-\alpha}{2}}^{[m]} = \chi_{0.975}^{[24]} = 39.364 \quad \& \quad \chi_{\frac{\alpha}{2}}^{[m]} = \chi_{0.025}^{[24]} = 12.401$$

ومن ثم ينتج لدينا أن $100(1-\alpha)\%$ فترة ثقة لـ σ^2 هي:

$$\left(\frac{(n-1)s^2}{\chi_{\frac{1-\alpha}{2}}^{[n-1]}}, \frac{(n-1)s^2}{\chi_{\frac{\alpha}{2}}^{[n-1]}} \right) = \left(\frac{24(110.43)^2}{39.364}, \frac{16(110.43)^2}{12.401} \right) = (7435.09, 23600.91)$$

(١٠, ٣, ٣) فترة الثقة لمعلمة مجتمع برنولي

سنفترض على مدى هذه الفقرة أنه لدينا $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X خاضع لتوزيع برنولي بمعلمة $0 < p < 1$ ، وأن $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ عينة من هذا المجتمع. عندئذ تفيدنا مبرهنة النهاية المركزية لموافير-لابلاس أنه سيكون للمتغير العشوائي:

$$B := \frac{(\bar{\pi} - p)}{\sqrt{\frac{p(1-p)}{n}}} = \sqrt{\frac{n}{p(1-p)}} (\bar{\pi} - p) \quad [10,27]$$

توزيع طبيعي معياري $N(0, 1)$ ، علماً أنَّ $\bar{\pi} = \frac{1}{n} \sum_{i=1}^n X_i$ يمثل التكرار النسبي للنجاحات في العينة وهو مقدر غير منحاز لمعلمة المجتمع p ، لأنَّ $E \bar{\pi} = p$ ، وكذلك لدينا $\text{var } \bar{\pi} = \frac{p(1-p)}{n}$.

إنَّ المبرهنة الآتية (ستقبلها دون برهان) تُعطينا $100(1-\alpha)\%$ فترة ثقة لمعلمة المجتمع البرنولي.

(١٠، ٣، ٣، ١) مبرهنة

تحت الفرضيات المذكورة آنفاً، تُعطى $100(1-\alpha)\%$ فترة ثقة للمعلمة p من خلال الفترة الآتية:

$$\left(\frac{\bar{p} + \frac{\chi^2_{1-\frac{\alpha}{2}}}{2n} - \frac{\chi_{1-\frac{\alpha}{2}}}{\sqrt{n}} \sqrt{\bar{p}(1-\bar{p}) + \frac{\chi^2_{1-\frac{\alpha}{2}}}{4n}}}{1 + \frac{\chi^2_{1-\frac{\alpha}{2}}}{n}}, \frac{\bar{p} + \frac{\chi^2_{1-\frac{\alpha}{2}}}{2n} + \frac{\chi_{1-\frac{\alpha}{2}}}{\sqrt{n}} \sqrt{\bar{p}(1-\bar{p}) + \frac{\chi^2_{1-\frac{\alpha}{2}}}{4n}}}{1 + \frac{\chi^2_{1-\frac{\alpha}{2}}}{n}} \right)$$

علماً أنَّ \bar{p} هي قيمة الإحصاء $\bar{\pi}$.

(١٠، ٣، ٣، ٢) ملاحظات

١- من الناحية التطبيقية يمكننا إهمال قيم الحدود $\frac{\chi^2_{1-\frac{\alpha}{2}}}{n}$ و $\frac{\chi^2_{1-\frac{\alpha}{2}}}{2n}$ و $\frac{\chi^2_{1-\frac{\alpha}{2}}}{4n}$ في الفترة السابقة وذلك بسبب صغر المقدار $\chi_{1-\frac{\alpha}{2}}$ بالمقارنة مع قيم n التي تُؤخذ كبيرة بقدر كافٍ في معظم الدراسات الإحصائية، وذلك لأنَّه في حالة كانت قيمة $\chi_{1-\frac{\alpha}{2}}$ ليست صغيرة بما فيه الكفاية بالنسبة إلى قيمة n فإنَّ تقريب موافير-لابلاس يصبح غير ممكن في تعيين فترة الثقة الأخيرة، ولذلك سنستخدم الفترة الآتية عوضاً عن الفترة السابقة على أنَّها $100(1-\alpha)\%$ فترة ثقة للمعلمة p :

$$\left(\bar{p} - \chi_{1-\frac{\alpha}{2}} \sqrt{\frac{\bar{p}(1-\bar{p})}{n}}, \bar{p} + \chi_{1-\frac{\alpha}{2}} \sqrt{\frac{\bar{p}(1-\bar{p})}{n}} \right) \quad [10,28]$$

وتزداد دقة استخدام هذه الفترة كلما كبرت قيمة n ، وعلى العموم يمكننا قبول هذه الفترة عندما يكون $32 \leq n$ مع تحقق المتباينتين $5 < np$ و $5 < n(1-p)$ أيضاً.

٢- نلاحظ هنا أنَّ تقديرنا لمعلمة المجتمع p بالقيمة \bar{p} سيرافقه خطأ أعظمي er مقداره يساوي:

$$er = \pm \chi_{1-\frac{\alpha}{2}} \sqrt{\frac{\bar{p}(1-\bar{p})}{n}} \quad [10,29]$$

٣- يمكننا تقدير حجم العينة n التي يجب سحبها من المجتمع بحيث لا يتجاوز الخطأ المرتكب في تقديرنا للمعلمة p بالقيمة \bar{p} بأكثر من er ، وذلك باستخدام المتباينة الآتية:

$$n \geq \left(\frac{\chi_{1-\frac{\alpha}{2}}}{er} \right)^2 \bar{p}(1-\bar{p}) \quad [10,30]$$

(١٠, ٣, ٣, ٣) أمثلة

١- تدعي مؤسسة تعليمية أنها على ثقة قدرها % 98 بأن نسبة الطلبة المتعثرين لديها لا تتجاوز 0.05، فأرادت دائرة الجودة (التي تتبعها هذه المؤسسة) التحقق من صحة ادعاء هذه المؤسسة التعليمية، فقامت بسحب عينة من طلاب هذه المؤسسة بحجم 256 طالباً، وبحثت في سجل كل طالب من هذه العينة لدى المؤسسة فوجدت 16 طالباً متعثراً، فهل تشير هذه النتيجة إلى صحة ادعاء المؤسسة التعليمية عند مستوى الثقة الذي قدمته هذه المؤسسة؟

الحل: بملاحظة أن تفحص سجل كل طالب هي تجربة برنولية، فإن ذلك يعني أننا أمام مجتمع برنولي (ذلك أن أي طالب إما أن يكون متعثراً أو غير متعثر) بمعلمة $p = 0.05$ (هنا الحصول على طالب متعثر يعد نجاحاً)، ولكن بسبب الشك في قيمة هذه المعلمة فإننا سنتعامل معها على أنها مجهولة، ولذلك فمن أجل الإجابة على السؤال الطروح علينا تعيين %98 فترة ثقة للمعلمة p ، وبما أن حجم العينة كبير وتفحص سجلات الطلاب هو تكرارات مستقلة عن بعضها، فعندئذ تُعطى فترة الثقة المطلوب تعيينها بوساطة [10-28]، حيث لدينا من معطيات المسألة ما يلي:

$$\bar{p} = \frac{16}{256} = 0.0625 \quad \& \quad z_{1-\frac{\alpha}{2}} = z_{0.99} = 2.33$$

ومن ثم تكون لدينا %98 فترة ثقة للمعلمة p هي:

$$\left(0.0625 - 2.33 \sqrt{\frac{0.0625(1-0.0625)}{16}}, 0.0625 + 2.33 \sqrt{\frac{0.0625(1-0.0625)}{16}} \right)$$

وبعد تنفيذ الحسابات نحصل على الفترة (0.2035 و -0.0785)، ومن ثم نقبل بادعاء هذه المؤسسة التعليمية عند مستوى الثقة 0.98 لأن نسبة الطلبة المتعثرين التي قدمتها 0.05 تنتمي إلى هذه الفترة.

٢- نقوم بدراسة ميدانية حول تأثير نوع من الأسمدة على إنتاج محصول زراعي، وأردنا التحقق من نتيجة هذه التجربة بحيث إنه عند مستوى من الثقة قدره %95 يجب أن تكون الفوارق التي سنحصل عليها في حدود ± 0.05 من النسبة الحقيقية لنجاح هذه التجربة، وهذا يعني أن الخطأ المرتكب في تقدير p بالتكرار النسبي للنجاحات في العينة \bar{p} يجب أن يكون في حدود ± 0.05 . فإذا كانت التجارب الخاصة بهذه النتيجة تكرر بشكل مستقل بعضها عن بعض وتحت الشروط نفسها، فعندئذ كم مرة يجب أن نكرر التجربة عند مستوى ثقة قدره %95 لكي يكون الفارق في حدود ± 0.15 من النسبة الحقيقية لنجاح هذه التجربة، وذلك من أجل الحالتين الآتيتين:

أ- إذا علمنا من باحثين آخرين أن نسبة النجاح لهذه التجربة هو 0.10 ؟

ب- إذا كنا لا نعلم شيئاً عن نسبة النجاح لهذه التجربة؟

الحل: للإجابة على هذه الأسئلة لدينا من أجل الطلب:

أ- نجد من معطيات المسألة أن:

$$er = \pm 0.15 \quad \& \quad \bar{p} = 0.10 \quad \& \quad z_{1-\frac{\alpha}{2}} = z_{0.975} = 1.96$$

ومن ثم عدد التجارب التي يجب تكرارها تُقدر بالمتباينة [10-30]، وبالتعويض في تلك المتباينة نجد أن:

$$n \geq \left(\frac{1.96}{0.15} \right)^2 (0.10)(0.90) = 15.3664$$

ومن ثم يجب تكرار هذه التجربة 16 مرة على الأقل حتى يصبح الفارق في حدود ± 0.15 من النسبة الحقيقية لنجاح هذه التجربة.

ب- نجد من معطيات المسألة أن:

$$er = \pm 0.15 \quad \& \quad \bar{p} = ? \quad \& \quad \bar{z}_{1-\frac{\alpha}{2}} = \bar{z}_{0.975} = 1.96$$

ونلاحظ أنه لا بد من تعيين قيمة \bar{p} أولاً. إن ذلك يتم من خلال حساب قيمة \bar{p} التي يكون فيها للدالة $f(\bar{p}) = \bar{p}(1-\bar{p})$ نهاية عظمى، وفي هذا الصدد يمكن التحقق بسهولة من أن $f(\bar{p})$ يكون لها نهاية عظمى عندما يكون $\bar{p} = \frac{1}{2}$ وذلك من خلال وضع $f'(\bar{p}) = 0$ ، ومن ثم تكون أكبر قيمة لـ n التي من أجلها نحافظ على الدقة المطلوبة (المتضمنة بالخطأ er) آنفاً وبغض النظر عن القيمة الفعلية لنسبة نجاح التجربة \bar{p} تعطى وفقاً للمتباينة [10-30] بالقيمة $42.684 \leq n$ ، وهذا يعني أنه في هذه الحالة يجب تكرار هذه التجربة 43 مرة على الأقل.

(١٠, ٣, ٤) فترات الثقة للفرق بين متوسطي مجتمعين طبيعيين مستقلين ونسبة تشتتهما

سنفرض على مدى هذه الفقرة أنه لدينا مجتمعين طبيعيين مستقلين. في مثل هذه الحالات يناقش تعيين فترات الثقة الخاصة بالفرق بين متوسطي هذين المجتمعين، وكذلك تعيين فترات الثقة الخاصة بنسبة التباين لهما.

ليكن $[\Omega_1, \delta_1, \mathcal{P}_1]$ مجتمعاً موصوفاً من خلال متغير عشوائي X خاضع للتوزيع الطبيعي $N(\mu_1, \sigma_1)$ ، و $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ عينة مسحوبة من هذا المجتمع بمتوسط \bar{X} وانحراف معياري s_X . كذلك ليكن $[\Omega_2, \delta_2, \mathcal{P}_2]$ مجتمع آخر مستقل عن المجتمع السابق، وموصوف من خلال متغير عشوائي Y خاضع للتوزيع الطبيعي $N(\mu_2, \sigma_2)$ ، ولنأخذ $\mathcal{Y}_m = (Y_1, Y_2, \dots, Y_m)$ عينة مسحوبة من هذا المجتمع الأخير بمتوسط \bar{Y} وانحراف معياري s_Y .

تقدم لنا المبرهنة الآتية (التي سنقبلها دون برهان) فترات الثقة للفرق بين متوسطي مجتمعين طبيعيين.

(١٠, ٣, ٤, ١) مبرهنة

تحت الفرضيات المذكورة آنفاً، فإنه لإعطاء $\% (1-\alpha) 100$ فترة ثقة للفرق $\mu_1 - \mu_2$ سنناقش الحالات الآتية:

١- إذا كان الانحراف المعياري لكل من المجتمعين معلوماً بحيث $\sigma_1 = \sigma_{1,o}$ و $\sigma_2 = \sigma_{2,o}$ ، فإن $\% (1-\alpha) 100$ فترة ثقة للفرق $\mu_1 - \mu_2$ تُعطى من خلال الفترة الآتية:

$$\left((\bar{X} - \bar{Y}) - \bar{z}_{1-\frac{\alpha}{2}} \sqrt{\frac{\sigma_{1,o}^2}{n} + \frac{\sigma_{2,o}^2}{m}} , (\bar{X} - \bar{Y}) + \bar{z}_{1-\frac{\alpha}{2}} \sqrt{\frac{\sigma_{1,o}^2}{n} + \frac{\sigma_{2,o}^2}{m}} \right) \quad [10,31]$$

٢- إذا كان الانحراف المعياري لكل من المجتمعين مجهولاً $\sigma_1 = ?$ و $\sigma_2 = ?$ ولكن مع الافتراض بتساويهما (أي أن $\sigma_1 = \sigma_2$)، فعندئذ تُعطى $\% (1-\alpha) 100$ فترة ثقة للفرق $\mu_1 - \mu_2$ من خلال الفترة التي لحديها الأدنى (الموافق لإشارة -) والأعلى (الموافق لإشارة +) العرض الآتي على الترتيب:

$$(\bar{X} - \bar{Y}) \mp t_{1-\frac{\alpha}{2}}^{n+m-2} \sqrt{\frac{(n+m)[(n-1)s_X^2 + (m-1)s_Y^2]}{nm(n+m-2)}} \quad [10,32]$$

٣- إذا كان الانحراف المعياري لكل من المجتمعين مجهولاً $\sigma_1 = ?$ و $\sigma_2 = ?$ ولكن مع الافتراض بعدم تساويهما (أي إن $\sigma_1 \neq \sigma_2$)، فإن دراسة هذه الحالة ليست بسيطة كما ذكرنا ذلك في الفصل السابق، حيث سيكون للمتغير العشوائي T^* الآتي (قدم في الفصل السابق بالعلاقة رقم [9-28]):

$$T^* = \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{(S_X^2 / n) + (S_Y^2 / m)}}$$

توزيع ستودنت على وجه التقريب، وحينئذ تُعطى $\% (1-\alpha) 100$ فترة ثقة تقريبية للفرق $\mu_1 - \mu_2$ من خلال الفترة الآتية:

$$\left((\bar{x} - \bar{y}) - t_{1-\frac{\alpha}{2}} \sqrt{\frac{(n-1)s_X^2 + (m-1)s_Y^2}{n \cdot m}}, (\bar{x} - \bar{y}) + t_{1-\frac{\alpha}{2}} \sqrt{\frac{(n-1)s_X^2 + (m-1)s_Y^2}{n \cdot m}} \right) \quad [10,33]$$

$$v = \left[\frac{\left(\frac{s_X^2}{n} + \frac{s_Y^2}{m} \right)^2}{\sqrt{\left[\left(s_X^2 / n \right)^2 / (n-1) \right] + \left[\left(s_Y^2 / n \right)^2 / (m-1) \right]}} \right]$$

علماً أنَّ عدد درجات الحرية v الموافقة لهذه الحالة تحسب من العلاقة المقدّمة جانباً (تقريب سايرثويت)، وأنَّ $[x]$ هو أصغر عدد صحيح أكبر من x .

(١٠, ٣, ٤, ٢) ملاحظة

من فترات الثقة السابقة [10-31] و [10-32] و [10-33]

نلاحظ ما يلي:

- ١- إذا كان الطرف الأيمن **سالِباً** لآية فترة من الفترات الثلاث السابقة، فعندئذ يكون لدينا $\mu_1 < \mu_2$ باحتمال قدره $1-\alpha$.
- ٢- إذا كان الطرف الأيسر **موجباً** لآية فترة من الفترات الثلاث السابقة، فعندئذ يكون لدينا $\mu_1 > \mu_2$ باحتمال قدره $1-\alpha$.
- ٣- إذا كان الطرف الأيمن **موجباً** والطرف الأيسر **سالِباً** لآية فترة من الفترات الثلاث السابقة، فعندئذ سيكون لدينا $\mu_1 = \mu_2$ باحتمال قدره $1-\alpha$ ، وما يظهر من فروق في قيم \bar{X} و \bar{Y} إنّها هي فروق ظاهرية لا أهميّة لها ما دامت قيمة $1-\alpha$ قريبة من الواحد.

المبرهنة الآتية تعطينا $\% (1-\alpha) 100$ فترة الثقة لنسبة تبايني مجتمعين طبيعيين.

(١٠, ٣, ٤, ٣) مبرهنة

تحت الفرضيات المقدّمة سابقاً في هذه الفقرة، فإنَّ $\% (1-\alpha) 100$ فترة ثقة للنسبة $\frac{\sigma_1^2}{\sigma_2^2}$ تُعطى من خلال الفترة الآتية:

$$\left(\frac{S_X^2}{S_Y^2} \cdot f_{\frac{\alpha}{2}}^{[m-1; n-1]}, \frac{S_X^2}{S_Y^2} \cdot f_{1-\frac{\alpha}{2}}^{[m-1; n-1]} \right) \quad [10,34-a]$$

ولكن بسبب أنَّ الجدول المقدم في ملحق الجداول الإحصائية في نهاية هذا الكتاب لا يعطينا قيماً للحد $f_{\frac{\alpha}{2}}^{[m-1; n-1]}$ من أجل

القيم الصغيرة لـ α ، ولذلك يُستعاض عن ذلك الحد بالمقدار $\left(f_{1-\frac{\alpha}{2}}^{[m-1; n-1]} \right)^{-1}$ ، حيث يُبرهن على أنَّ:

$$f_k^{[u; v]} = \left(f_{1-k}^{[u; v]} \right)^{-1} \quad \text{for } u, v \in \mathbb{N} \ \& \ 0 < k < 1$$

ومن ثمَّ يصبح للفترة [10-34-a] العرض الآتي:

$$\left(\frac{S_X^2}{S_Y^2} \cdot \left(f_{1-\frac{\alpha}{2}}^{[m-1; n-1]} \right)^{-1}, \frac{S_X^2}{S_Y^2} \cdot f_{1-\frac{\alpha}{2}}^{[m-1; n-1]} \right) \quad [10,34-b]$$

علماً أنَّ $f_k^{[u; v]}$ هي تلك النقطة على المحور الحقيقي التي يقع على يسارها وتحت منحنى الكثافة الاحتمالية لتوزيع **فيشر** ذي الـ u (درجة حرية بسط) و v (درجة حرية مقام) مساحة قدرها k .

(١٠, ٣, ٤, ٤) نتائج

من فترة الثقة [10,34-a] أو [10,34-b] نستنتج ما يلي:

- ١- إذا كان الطرف الأيسر للفترة الأخيرة أكبر من الواحد، فعندئذ سيكون لدينا $\sigma_1^2 > \sigma_2^2$ باحتمال قدره $1-\alpha$.
- ٢- إذا كان لدينا الطرف الأيمن للفترة الأخيرة أصغر من الواحد، فعندئذ سيكون $\sigma_1^2 < \sigma_2^2$ باحتمال قدره $1-\alpha$.
- ٣- إذا كان لدينا الطرف الأيمن للفترة الأخيرة أكبر من الواحد وطرفها الأيسر أصغر من الواحد، فعندئذ سيكون لدينا $\sigma_1^2 = \sigma_2^2$ باحتمال قدره $1-\alpha$ ، ومن ثم باحتمال قدره $1-\alpha$ سيكون التباين للمجتمعين متساويين، وما يظهر من فوارق في قيم S_Y^2 و S_X^2 إنما هي فوارق ظاهرية لا أهمية لها مادام مستوى الثقة $1-\alpha$ قريب من الواحد.

(١٠, ٣, ٤, ٥) مثال

تقدّمت شركتان مستقلّتان بعضهما عن بعض لإنتاج الأطعمة المعلّبة (الكنسروة) بعروض بيع لمتجها لإحدى المؤسسات المهتمة بهذا النوع من التجارة. حيث ادّعت الشركة الأولى أنّها على ثقة قدرها 0.98 بأنّ متوسط وزن العلبة لديها 1000 غرام بانحراف معياري قدره 50 غراماً، في حين ادّعت الشركة الثانية أنّها على ثقة قدرها 0.98 بأنّ متوسط وزن العلبة لديها 1050 غراماً بانحراف معياري قدره 25 غراماً. لكي تقرّر المؤسسة أي الشركتين ستختار قامت بأخذ عينة X_{81} من الشركة الأولى فوجدت أنّ متوسط وزن العلبة في هذه العينة $\bar{x} = 1050$ غراماً بانحراف معياري $s_x = 45$ غراماً، وكذلك أخذت عينة Y_{64} من الشركة الثانية فوجدت أنّ متوسط وزن العلبة في هذه العينة $\bar{y} = 1025$ غراماً بانحراف معياري $s_y = 50$ غراماً. الآن، لو افترضنا أنّ أوزان العلب تخضع للتوزيع الطبيعي، فأأي الشركتين يُفضّل اختيارها من قبل المؤسسة عند مستوى من الثقة 0.98؟

الحل: للإجابة على هذا السؤال علينا القيام بتعيين 98% فترة ثقة للفرق $\mu_1 - \mu_2$ ، وهنا علينا أن نناقش الحالات الآتية:

- أ- إذا أخذنا بقيم الانحراف المعياري المقدّمة من قبل الشركتين، وهذا يعني أنّ التباين لكلّ من مجتمعي العلب معلوم حيث لدينا بخصوص العينة والمجتمع الأول $n = 81$ ، $\bar{x} = 1050$ و $\sigma_{1,o} = 50$ ، وأما بخصوص العينة والمجتمع الثاني فلدينا $m = 64$ ، $\bar{y} = 1025$ و $\sigma_{2,o} = 25$ ، وعلاوة على ذلك لدينا $z_{1-\frac{\alpha}{2}} = z_{1-0.01} = z_{0.99} = 2.33$ ، ومن ثمّ تُعطى 98 % فترة ثقة للفرق $\mu_1 - \mu_2$ من خلال الفترة [10-31]، وبالتعويض عن كلّ رمز بما يساويه يكون لحدي هذه الفترة العرض الآتي:

$$(\bar{x} - \bar{y}) \pm z_{1-\frac{\alpha}{2}} \sqrt{\frac{\sigma_{1,o}^2}{n} + \frac{\sigma_{2,o}^2}{m}} = (1050 - 1025) \pm 2.33 \sqrt{\frac{2500}{81} + \frac{625}{64}}$$

والتي تعطينا الفترة (10.15 و 39.85)، وبما أنّ طرفي هذه الفترة موجب فإنّ ذلك يعني أنّ $\mu_2 < \mu_1$ باحتمال قدره 0.98، ومن ثمّ نفضّل اختيار الشركة الأولى لأنّ متوسط وزن العلب أكبر من مثيلاتها لدى الشركة الثانية.

- ب- إذا تجاهلت المؤسسة قيم الانحراف المعياري المقدّمة من قبل الشركتين، وهذا يعني أنّ التباين لكلّ من مجتمعي العلب مجهول حيث لديها في هذه الحالة $\sigma_1 = ?$ و $\sigma_2 = ?$ ، وبما أنّ التباين لكلّ من مجتمعي العلب مجهولاً فعلياً أولاً أنّ نبيّن إن كان $\sigma_1^2 = \sigma_2^2$ أو لا.

من أجل ذلك علينا تعيين 98% فترة ثقة للنسبة $\frac{\sigma_1^2}{\sigma_2^2}$ ، علماً أنّ $(1-\alpha) 100\%$ فترة ثقة لهذه النسبة تُعطى من خلال الفترة

[10-34-b]، حيث لدينا من جدول توزيع فيشر:

$$f_{1-\frac{\alpha}{2}}^{[m-1; n-1]} = f_{0.99}^{[63; 80]} \approx f_{0.99}^{[60; 60]} = 1.84$$

ومن ثمّ يكون للفترة المذكورة آنفاً العرض الآتي:

$$\left(\frac{S_X^2}{S_Y^2} \cdot f_{1-\frac{\alpha}{2}}^{[m-1; n-1]} \right)^{-1}, \frac{S_X^2}{S_Y^2} \cdot f_{1-\frac{\alpha}{2}}^{[m-1; n-1]} = \left(\frac{2025}{2500} \cdot \frac{1}{1.84}, \frac{2025}{2500} \cdot 1.84 \right) = (0.440, 1.490)$$

وبما أن طرفها الأيسر أصغر من الواحد، والأيمن أكبر من الواحد؛ فإن ذلك يعني أن $\sigma_1^2 = \sigma_2^2$ عند مستوى الثقة 98%، وبالتالي تُعطى 98 % فترة ثقة للفرق $\mu_1 - \mu_2$ من خلال الفترة التي لحديها الأدنى والأعلى العرض [10-32]، حيث لدينا من جدول توزيع ستودنت $t_{1-\frac{\alpha}{2}}^{[m+n-2]} = t_{0.99}^{[143]} = 2.33$ ، وبالتعويض عن كل رمز بما يساويه في العرض [10-32] نجد لحدي الفترة العرض الآتي:

$$(\bar{x} - \bar{y}) \mp t_{1-\frac{\alpha}{2}}^{[m+n-2]} \sqrt{\frac{(n+m)[(n-1)s_X^2 + (m-1)s_Y^2]}{nm(n+m-2)}} = (1050 - 1025) \pm 2.33 \sqrt{\frac{(81+64)[(80)2025 + (63)2500]}{(81)(64)(143)}}$$

والتي تعطينا الفترة (43.42 و 6.58)، وفي هذه الحالة نجد أن $\mu_2 < \mu_1$ باحتمال قدره 0.98 أيضاً، ومن ثم نفضل اختيار الشركة الأولى أيضاً.

(١٠, ٣, ٥) فترة الثقة للفرق بين معلمتي مجتمعين برنوليين مستقلين

ليكن $[\Omega_1, \mathcal{S}_1, \mathcal{P}_1]$ مجتمع برنولي بمعلمة p_1 ، ولنأخذ $\mathcal{X}_n = (X_1, X_2, \dots, X_n)$ عينة مسحوبة من هذا المجتمع. كذلك ليكن $[\Omega_2, \mathcal{S}_2, \mathcal{P}_2]$ مجتمعاً برنولياً آخر مستقل عن المجتمع السابق بمعلمة p_2 ، ولنأخذ $\mathcal{Y}_m = (Y_1, Y_2, \dots, Y_m)$ عينة مسحوبة من هذا المجتمع الثاني. علماً أن n و m قيم كبيرة بقدر كاف.

تُعطينا المبرهنة الآتية (التي سنقبلها دون برهان) $\%$ (1- α) فترة ثقة للفرق $p_1 - p_2$.

(١٠, ٣, ٥, ١) مبرهنة

تحت الفرضيات المقدمة آنفاً تُعطى $\%$ (1- α) فترة ثقة (تقريبية) للفرق $p_1 - p_2$ من خلال الفترة الآتية:

$$\left((\bar{p}_1 - \bar{p}_2) - \mathcal{Z}_{1-\frac{\alpha}{2}} \sqrt{\frac{\bar{p}_1(1-\bar{p}_1)}{n} + \frac{\bar{p}_2(1-\bar{p}_2)}{m}}, (\bar{p}_1 - \bar{p}_2) + \mathcal{Z}_{1-\frac{\alpha}{2}} \sqrt{\frac{\bar{p}_1(1-\bar{p}_1)}{n} + \frac{\bar{p}_2(1-\bar{p}_2)}{m}} \right) \quad [10,34]$$

علماً أن p_1 و p_2 هي قيمة الإحصاء $\bar{p}_1 = \frac{1}{n} \sum_{k=1}^n X_k$ و $\bar{p}_2 = \frac{1}{m} \sum_{k=1}^m Y_k$ الذي يمثل التكرار النسبي للنجاحات في العينة \mathcal{X}_n و \mathcal{Y}_m على الترتيب.

(١٠, ٣, ٥, ٢) ملاحظات

١- إن الفترة الأخيرة هي فترة تقريبية لـ $\%$ (1- α) فترة ثقة لـ $p_1 - p_2$ ، وتزداد دقة هذه الفترة كلما كبر حجم العييتين n و m ، وتكون مقبولة إلى حد ما عندما تكون قيمة كل من n و m أكبر من 32.

٢- إذا كان الطرف الأيمن من الفترة الأخيرة [10,34] سالباً فإنه سيكون لدينا $p_2 > p_1$ باحتمال قدره (1- α).

٣- إذا كان الطرف الأيسر من الفترة الأخيرة [10,34] موجباً فإنه سيكون لدينا $p_2 < p_1$ باحتمال قدره (1- α).

٤- إذا كان الطرف الأيمن للفترة الأخيرة [10,34] موجباً وطرفها الأيسر سالباً، فعندئذ يكون $p_1 = p_2$ باحتمال قدره (1- α)، ومن ثم فإن ما يظهر من فوارق في قيم الإحصاءتين \bar{p}_1 و \bar{p}_2 هي فوارق ظاهرية لا أهمية لها ما دامت قيمة (1- α) قريبة من الواحد.

(١٠, ٣, ٥, ٣) مثال

في مصنع للأدوات الكهربائية توجد آلتان M_1 و M_2 لإنتاج الملفات المستخدمة في تصنيع المحركات الكهربائية، وتعمل كل منهما بشكل مستقل عن الأخرى، قمنا بسحب عينة من إنتاج M_1 بحجم $n = 196$ ملفاً فوجدنا فيها 13 ملفاً غير صالحة للعمل، وكذلك قمنا بسحب عينة أخرى من إنتاج M_2 بحجم $m = 225$ ملفاً فوجدنا فيها 15 ملفاً غير صالحة للعمل. هل تدل هذه المعطيات على أن لآلتين M_1 و M_2 الكفاءة نفسها في الإنتاج عند مستوى الثقة 98%؟

الحل: من أجل ذلك لنقم بتعيين 98% فترة ثقة للفرق $p_1 - p_2$ علماً أن الفترة المطلوبة لذلك تُعطى بالفترة [10,34] حيث لدينا من معطيات المسألة $\bar{p}_1 = \frac{13}{196} = 0.066$ و $\bar{p}_2 = \frac{15}{225} = 0.067$ ، ومن جدول التوزيع الطبيعي المعياري نجد أن $z_{1-\frac{\alpha}{2}} = z_{0.99} = 2.33$ ، ومن ثم نجد أن لحدّي الفترة [10,34] العرض الآتي:

$$(0.066 - 0.067) \mp 2.33 \sqrt{\frac{0.066(1-0.066)}{196} + \frac{0.067(1-0.067)}{225}}$$

والتي نجد منها أن 98% فترة ثقة للفرق $p_1 - p_2$ هي (0.0576 و -0.0556)، وهذا يعني أنه لآلتين M_1 و M_2 الكفاءة نفسها في الإنتاج عند مستوى الثقة 98%؛ وذلك لأن الحد الأدنى لهذه الفترة سالب في حين حدّها الأعلى موجب.

نقدم فيما يلي بعض التطبيقات على استخدام برنامج Minitab في مجال تعيين فترات الثقة.

(١٠, ٤) تطبيقات

(١٠, ٤, ١) تطبيق

لنكن لدينا البيانات الآتية التي تمثل الأوزان لـ 64 شخصاً بالغاً مقدرة بالكيلو غرام:

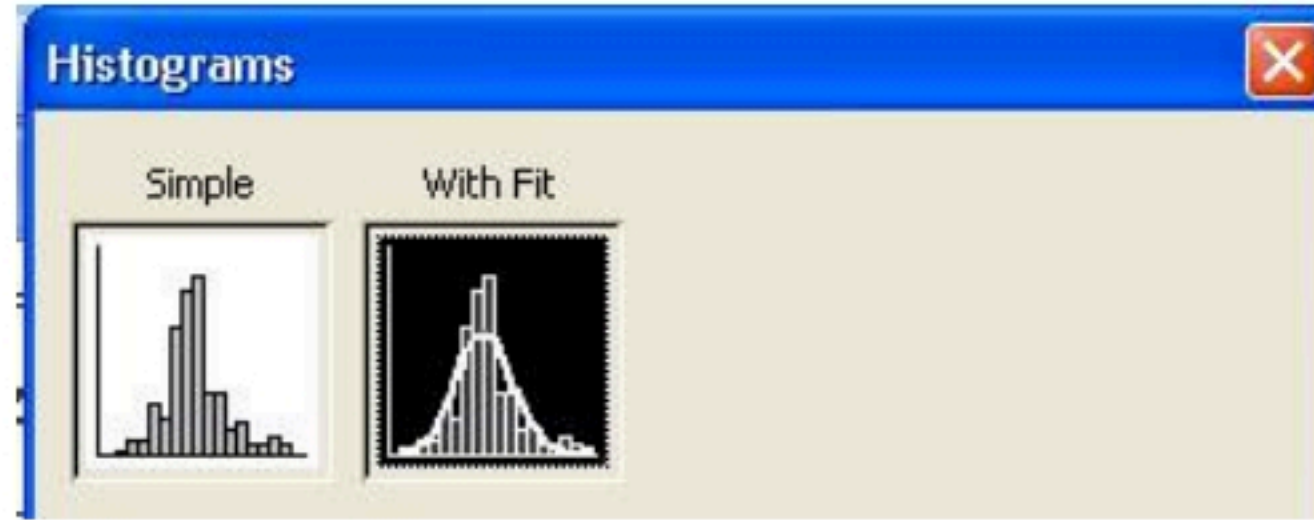
69	94	83	59	79	74	73	87	84	90	89	81	70	53	71	61
76	87	65	61	78	83	75	88	65	93	66	66	99	57	98	60
59	72	80	58	91	68	82	67	79	52	74	76	77	73	80	89
78	72	62	96	73	82	55	56	86	84	54	63	85	76	76	64

ولننظر أولاً إن كانت هذه البيانات تتوزع طبيعياً أو لا.

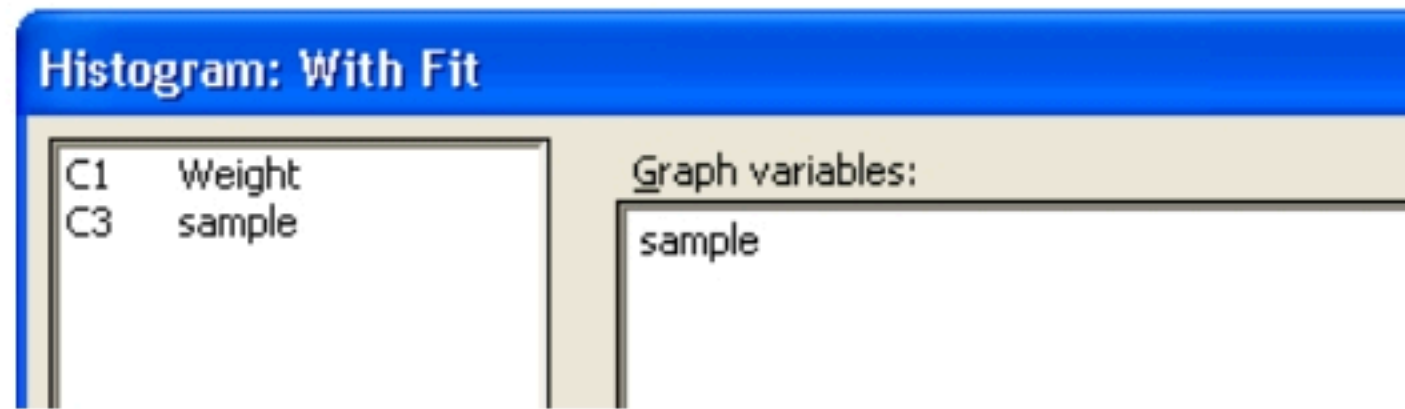
من أجل ذلك سنحاول الاستدلال على شكل التوزيع من خلال مدرجه التكراري ومقارنته مع التوزيع الطبيعي مستخدمين في ذلك برنامج Minitab وفقاً للخطوات الآتية:

Graph → Histogram → With Fit → Graph variables → OK






ومن ثمَّ



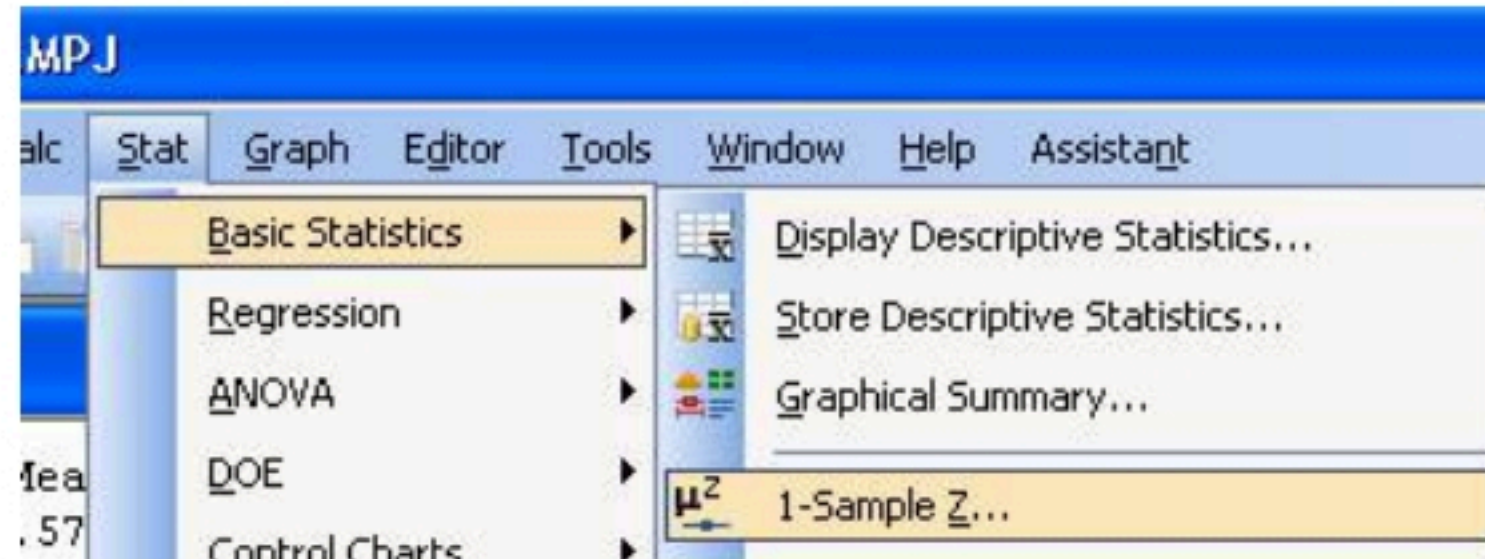
وبعد ذلك تفعيل OK فنحصل على الشكل الآتي الممثل للمدرج التكراري مع منحنى التوزيع الطبيعي الملائم لهذه البيانات:



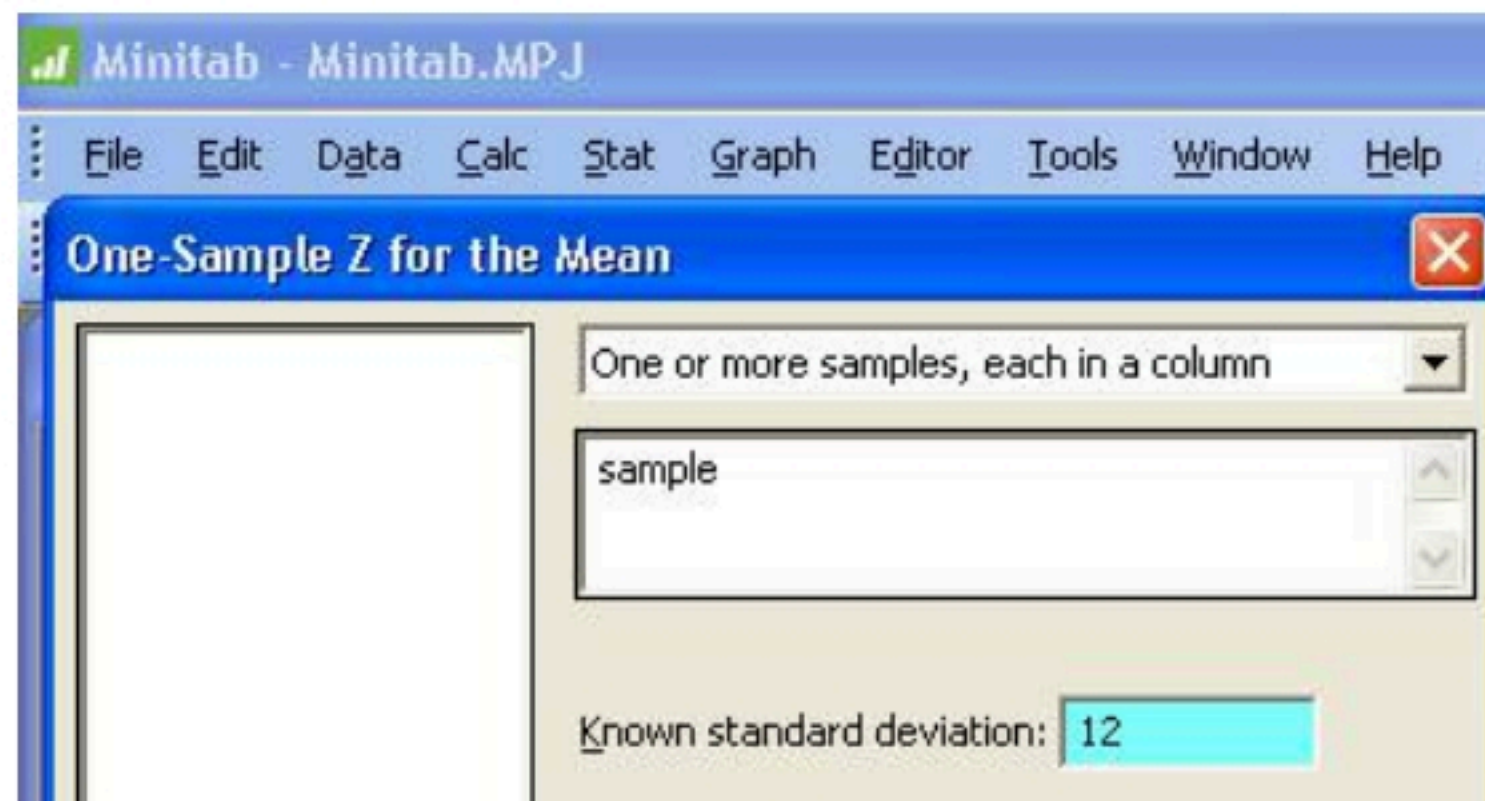
فلاحظ أنَّ هذا العرض يظهر تقارباً جيداً مع منحنى دالة الكثافة الاحتمالية للتوزيع الطبيعي، ويزودنا هذا العرض بقيمة المتوسط $\bar{x} = 74.578$ والانحراف المعياري $s = 12.135$ ، وأما من أجل اختبار إن كانت هذه البيانات تقبل التوزيع الطبيعي كتوزيع مناسب فعلاً فإننا سنترك ذلك إلى التطبيقات المقدمة في نهاية الفصل القادم (اختبار الفرضيات الإحصائية).

الآن لتعيين α (1 - α) 100 فترة ثقة لـ μ متوسط مجتمع هذه البيانات، فإننا نعلم أنه علينا أن نميز بين حالتين هما:
أ- إذا افترضنا أن الانحراف المعياري للمجتمع معلوم ويساوي $\sigma = \sigma_0 = 12$ ، فعندئذ نتبع الخطوات الآتية (مستخدمين توزيع Z - أو الطبيعي -):

Stat → Basic Statistics → 1-Sample Z → Known standard deviation → OK.



ومن ثم الخطوة التالية



وبعد ذلك تفعيل OK فنحصل على التقرير الآتي الذي يحتوي على 95% فترة ثقة للمتوسط μ .

One-Sample Z: sample

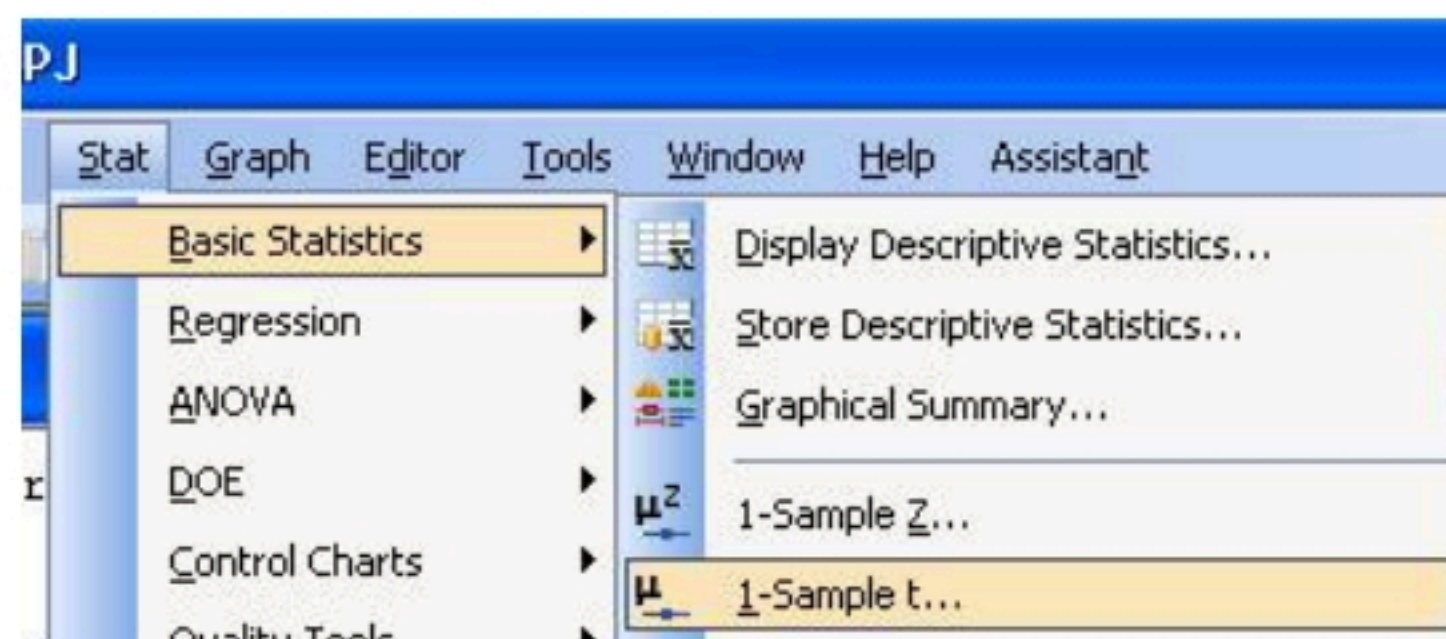
The assumed standard deviation = 12

Variable	N	Mean	St Dev	SE Mean	95% CI
sample	64	74.58	12.14	1.50	(71.64, 77.52)

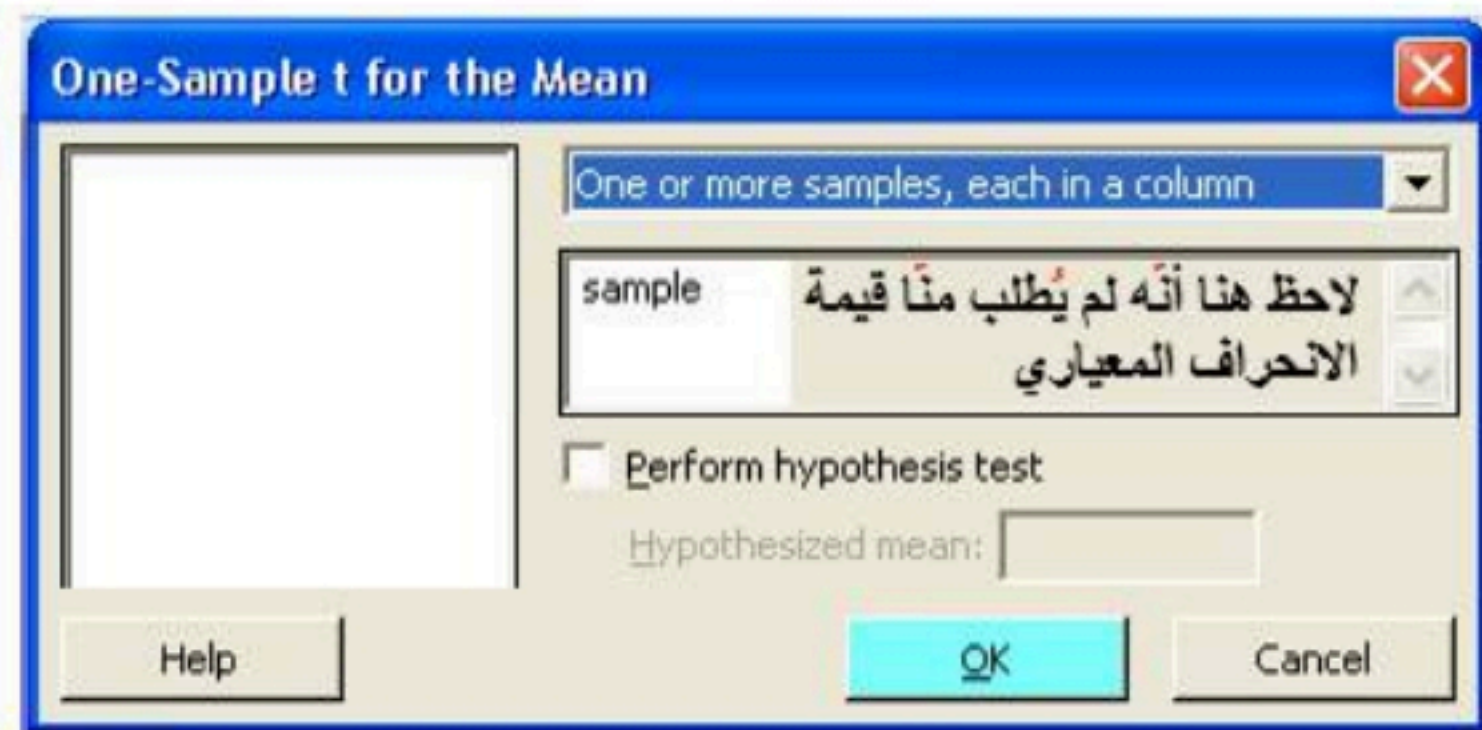
ب- إذا افترضنا أن الانحراف المعياري للمجتمع مجهول $\sigma = ?$ ، فعندئذ نتبع الخطوات الآتية (مستخدمين توزيع t - أو

ستودنت-):

Stat → Basic Statistics → 1-Sample t → Known standard deviation → OK



ومن ثم الخطوة التالية



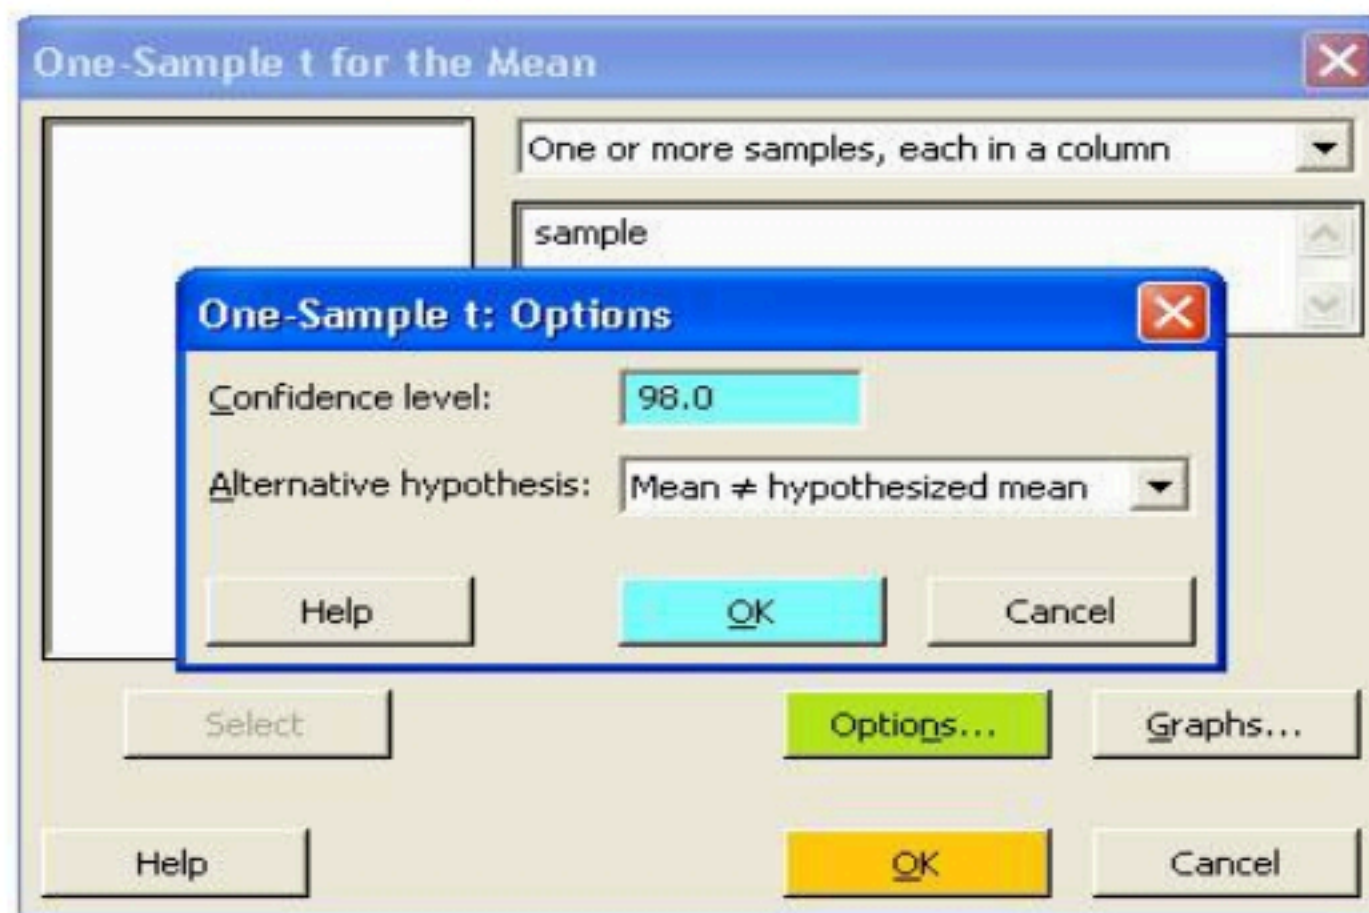
وبتفعيل OK نحصل على التقرير الآتي الذي يحتوي على 95% فترة ثقة للمتوسط μ .

One-Sample T: sample

Variable	N	Mean	St Dev	SE Mean	95% CI
sample	64	74.58	12.14	1.52	(71.55 , 77.61)

وإذا كنا نرغب في تغيير مستوى الثقة فإنه يمكننا التعديل على هذه القيمة من خلال المرحلة قبل الأخيرة على النحو الآتي:

One - Sample t for the mean → Option → Confidence level → OK → OK



فنحصل على التقرير الآتي الذي يحتوي على 98% فترة ثقة للمتوسط μ حسب كل حالة على حدة.

One-Sample Z: sample, The assumed standard deviation = 12

Variable	N	Mean	St Dev	SE Mean	98% CI
sample	64	74.58	12.14	1.50	(71.09 , 78.07)

One-Sample T: sample, The assumed standard deviation = 12

Variable	N	Mean	St Dev	SE Mean	98% CI
sample	64	74.58	12.14	1.52	(70.96 , 78.20)

وأما لتعيين 95% فترة ثقة لـ σ^2 تبين مجتمع البيانات المقدمة فإننا نتبع الخطوات الآتية:

Stat → Basic Statistics → 1Variance → Insert sample in free space → OK.

فنحصل على التقرير الآتي الذي يحتوي على 95% فترة ثقة لكل من σ الانحراف المعياري و σ^2 التباين لمجتمع البيانات المقدمة.

Test and CI for One Variance: sample

Method: The chi-square method is only for the normal distribution.

Variable	N	St Dev	Variance
sample	64	12.1	147
95% Confidence Intervals		St Dev	Variance
		(10.3; 14.7)	(106.09; 216.09)

(١٠, ٤, ١, ١) ملاحظة

بأسلوب مماثل يمكننا الحصول على العروض وفترات الثقة الخاصة بفرق المتوسطين $\mu_1 - \mu_2$ ونسبة التباين σ_1^2 / σ_2^2 لمجتمعين طبيعيين، ولكن يجب الانتباه إلى أن هذا البرنامج يشترط أن يكون للعينتين اللتين ستخضعان للدراسة الحجم نفسه.

(١٠, ٤, ٢) تطبيق

لتكن لدينا البيانات الآتية (تحت مسمى **Bi-sample**) التي تمثل عينة بحجم 81 شخصاً استطلعت آراءهم حول مشروع تنموي، علماً أن الإجابة "موافق" مُثلت بالعدد 1 في حين مُثلت الإجابة "غير موافق" بالعدد 0.

1	0	1	1	1	1	0	1	1	1	1	1	1	1	1	0	1	1	1	1
0	1	1	1	1	1	1	1	0	1	1	1	1	1	1	1	1	1	1	1
1	0	1	1	1	1	1	1	1	1	1	0	1	1	1	1	1	0	0	1
0	1	0	1	1	1	1	1	1	1	0	1	1	0	1	1	1	1	1	1

فعندئذ يمكننا استخدام برنامج Minitab للحصول على $\% (1-\alpha)$ 100 فترة ثقة لـ p معلمة مجتمع هذه البيانات وذلك وفقاً للخطوات الآتية:

Stat → Basic Statistics → 1-Proportion → Insert Bi-sample in free space → OK.

فنحصل على التقرير الآتي الذي يحتوي على 95% فترة ثقة لـ p معلمة مجتمع هذه البيانات المقدمة.

Test and CI for One Proportion: Bi-sample

Event = 1

Variable	X	N	Sample p	95% CI
Bi-sample	68	81	0.839506	(0.741200; 0.911681)

(١٠, ٤, ٢, ١) ملاحظة

بأسلوب مماثل تماماً يمكننا الحصول على العروض وفترات الثقة الخاصة بفرق الوسطين $p_1 - p_2$ لمجتمعين برنولييين، ولكن يجب الانتباه هنا إلى أن هذا البرنامج يشترط أن يكون للعينتين اللتين ستخضعان للدراسة الحجم نفسه أيضاً.

هذا ما تيسر تقديمه من أجل الجزء النظري والتطبيقي لهذا الفصل

تمارين الفصل العاشر

١- ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X خاضع للتوزيع المنتظم المستمر على فترة $[a, b]$ مع $-\infty < a < b < +\infty$ ، ولنأخذ \mathcal{X}_n عينة من هذا المجتمع، والمطلوب استخدام طريقة العزوم في تعيين مقدرات معلّمتي هذا المجتمع.

٢- ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X بدالة كثافة احتمالية $f_X(x; \theta)$ معطاة من خلال العلاقة:

$$f_X(x; \theta) = \frac{1}{\theta} \mathbf{I}_{[0, \theta]}(x)$$

ولتكن \mathcal{X}_n عينة من هذا المجتمع، والمطلوب تعيين مقدر الأرجحية العظمى للمعلمة θ .

٣- ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X ، ولنأخذ \mathcal{X}_n عينة من هذا المجتمع، والمطلوب استخدام طريقة العزوم في تعيين مقدرات معلّمة هذا المجتمع في الحالتين الآتيتين:

أ- المجتمع يتبع التوزيع المنتظم المتقطع بمعلمة $n \in \mathbb{N}$.

ب- المجتمع يتبع التوزيع الهندسي بمعلمة $0 < p < 1$.

ومن ثمّ بين أيّ من هذه المقدرات هو مقدر غير منحاز، وأيها غير منحاز تقاربياً.

٤- ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X ، ولنأخذ \mathcal{X}_n عينة من هذا المجتمع، فعندئذ استخدم طريقة الأرجحية العظمى في تعيين مقدرات معلّمة هذا المجتمع في الحالات الآتية:

أ- المجتمع يتبع التوزيع الأسّي بمعلمة $0 < \lambda$.

ب- المجتمع يتبع توزيع برنولي بمعلمة $0 < p < 1$.

ج- المجتمع يتبع توزيع له دالة كثافة احتمالية:

$$f_X(x; \theta) = \theta x^{\theta-1} \mathbf{I}_{(0,1)}(x) \quad ; \theta > 0 \text{ \& } x \in \mathbb{R}$$

د- المجتمع يتبع توزيع له دالة كثافة احتمالية:

$$f_X(x; \theta) = \theta (1-x)^{\theta-1} \mathbf{I}_{(0,1)}(x) \quad ; \theta > 0 \text{ \& } x \in \mathbb{R}$$

هـ- المجتمع يتبع توزيع له دالة كثافة احتمالية:

$$f_X(x; \theta) = e^{\theta-x} \mathbf{I}_{(\theta, \infty)}(x) \quad ; \theta, x \in \mathbb{R}$$

ومن ثمّ بين أيّ من هذه المقدرات هو مقدر غير منحاز، وأيها غير منحاز تقاربياً.

٥- زعم أحد المتاجر أنّ متوسط أرباحه اليومية على مرور أيام السنة يساوي 1000 ريال سعودي، وبانحراف معياري قدره 25 ريالاً سعودي وذلك عند مستوى من الثقة قدره 98%. الآن، وللتأكد من صحة زعمه قمنا بحساب الأرباح اليومية لستة عشر يوماً متفرقة من السنة، فوجدنا المعطيات الآتية:

1000	1000	1010	900	1010	1100	1000	1000
800	950	850	950	950	1200	800	1300

والمطلوب ما يلي:

أ- إذا أخذنا بالمعطيات التي قَدَّمها صاحب المتجر، فهل يمكن القبول بزعمه حول متوسط أرباحه اليومية عند مستوى من الثقة قدره 98%؟

ب- إذا تجاهلنا المعطيات التي قَدَّمها صاحب المتجر، فهل يمكن القبول بزعمه حول متوسط أرباحه اليومية عند مستوى من الثقة قدره 98%؟

ج- ما هو الخطأ المرتكب في تقدير متوسط الأرباح اليومية للبائع بقيمة الإحصاء \bar{X} في كلٍّ من الحالتين الآتيتين:

- الأخذ بقيمة الانحراف المعياري المقدمة من قبل صاحب المتجر.

- تجاهل قيمة الانحراف المعياري المقدمة من قبل صاحب المتجر.

٦- في مؤسسة صناعية يوجد الآلاف من العاملين، فإذا علمنا أن الأجر الشهري للعمال يخضع للتوزيع الطبيعي $N(\mu, 30)$ ، فعندئذ كم يجب أن يكون حجم العينة المسحوبة من مجتمع العاملين بحيث إنه عند مستوى ثقة قدره 98% يكون الخطأ المرتكب في تقديرنا لقيمة μ بالقيمة $\bar{x} = 650$ يساوي ± 25 وحدة نقدية؟

٧- ادعى مصنع لإنتاج المدخرات الكهربائية ذات الجهد 12.3 V أن متوسط عمر المدخرات لديه يساوي 750 ساعة عمل بانحراف معياري قدره 13 ساعة عمل. الآن إذا افترضنا أنه يوجد 1000 مدخرة في مستودع إنتاج هذا المصنع، وقمنا بأخذ عينة من هذه المدخرات بحجم 36 مدخرة واستخدامها، فوجدنا أن متوسط عمر هذه المدخرات يساوي 725 ساعة عمل بانحراف معياري قدره 15 ساعة عمل، فإذا كانت أعمار المدخرات تخضع للتوزيع الطبيعي بمتوسط μ ، وانحراف معياري σ ، فعندئذ عين 90% فترة ثقة لمتوسط أعمار المدخرات الكهربائية في كلٍّ من الحالات الآتية:

أ- إذا تجاهلنا قيمة الانحراف المعياري المقدمة من قبل المصنع.

ب- إذا أخذنا بقيمة الانحراف المعياري المقدمة من قبل المصنع.

٨- يدعي مصنع لإنتاج المكثفات الكيميائية (تستخدم في الدوائر الإلكترونية والكهربائية) ذات السعة $1000\mu F$ أن نسبة القطع المعطلة في إنتاجه لا يتجاوز 0.025، وذلك عند مستوى من الثقة مقداره 95%، فإذا افترضنا أن جميع المكثفات النصيب نفسه في السحب، وقمنا بسحب عينة من إنتاج هذا المصنع بحجم 225 مكثفاً فوجدنا لدى فحصها 13 مكثفاً معيماً، والمطلوب:

أ- تحقق من صحة ادعاء المصنع عند مستوى من الثقة مقداره 95%.

ب- ما هو حجم العينة التي يجب سحبها بحيث لا يتجاوز الخطأ المرتكب في تقديرنا لمعلمة مجتمع المكثفات p بالقيمة $\bar{p} = 0.001$ (التي تمثل التكرار النسبي للمكثفات المعطلة التي ستظهر لدينا في العينة) بأكثر من ± 0.01 ؟

٩- نريد القيام بالتحقق من نتيجة تجربة ما بحيث إنه عند مستوى من الثقة 90% تكون الفوارق التي سنحصل عليها في حدود ± 0.06 من النسبة الحقيقية لنجاح هذه التجربة، فإذا كانت التجارب الخاصة بهذه المسألة تكرر بشكل مستقل بعضها عن بعض، وتحت الشروط نفسها، فعندئذ كم مرة يجب أن نكرر التجربة عند مستوى ثقة قدره 90% لكي يكون الفارق في حدود ± 0.08 من النسبة الحقيقية لنجاح هذه التجربة:

أ- إذا علمنا من باحثين آخرين أن نسبة النجاح لهذه التجربة هو 0.30؟

ب- إذا كنا لا نعلم شيئاً عن نسبة النجاح لهذه التجربة؟

١٠- عُرِضَ على إحدى شركات تجميع الحواسيب نوعاً من السواقات الليزرية من مصدرين A و B مستقلين بعضهما عن بعض، حيث ادعى المصدر A أنه على ثقة قدرها 0.99 بأن متوسط عمر السواقة لديه 1000 ساعة عمل بانحراف معياري قدره 15 ساعة عمل، بينما ادعى المصدر B أنه على ثقة قدرها 0.99 بأن متوسط عمر السواقة لديه 1050 ساعة عمل بانحراف معياري قدره 5 ساعات عمل. فلو افترضنا أن عمر السواقات يخضع للتوزيع الطبيعي، فأَي المصدرين يُفَضَّل، وذلك عند مستوى من الثقة قدره 0.99؟

١١- يقوم باحثان A و B كل منهما بشكل مستقل عن الآخر، بإجراء تجربة معينة وتحت الشروط نفسها، فقد قام الباحث A بتكرارات مستقلة لهذه التجربة عددها n مرة حيث تحققت النتائج المرجوة منها في n_1 مرة، وأما الباحث الآخر B فقد قام بتكرارات مستقلة لهذه التجربة عددها m مرة حيث تحققت النتائج المرجوة منها في m_1 مرة. عندئذ المطلوب ما يلي:

أ- إذا كان $n = m = 49$ و $n_1 = m_1 = 36$ ، فعندئذ عين 98% فترة ثقة للفرق بين وسيطي النجاح للتجربة التي نُفذت من قبل الباحثين.

ب- إذا كان $n = 81$ و $n_1 = 64$ و $m = 100$ و $m_1 = 49$ ، فعندئذ:

- بين عند أي مستوى من الثقة يمكننا أن نؤكد على أن قيمة معلمة نجاح التجارب لدى الباحث الأول A أصغر من قيمة معلمة النجاح لتجارب الباحث الآخر B .

- عند أي مستوى من الثقة يكون الخطأ المرتكب في تقديرنا للفرق $p_1 - p_2$ بقيمة الإحصائي $\bar{P}_1 - \bar{P}_2$ لا يتجاوز ± 0.005 .

١٢- في مصنع للحديد والصلب لدينا خطين مستقلين بعضهما عن الآخر لإنتاج القضبان الحديدية ذات الطول 5 أمتار وبقطر يساوي 12 مم. قمنا بسحب عينة X_m من إنتاج الخط الأول وعينة عشوائية أخرى Y_m من إنتاج الخط الثاني، فوجد أن متوسط قطر القضبان في العينة الأولى 12.1 مم بانحراف معياري قدره 0.5 مم وأما متوسط قطر القضبان في العينة الثانية فكان 11.9 مم بانحراف معياري قدره 0.2 مم، والمطلوب ما يلي:

أ- إذا كان $n = 49$ و $m = 36$ ، فعندئذ عين 95% فترة ثقة لفرق متوسط قطر القضبان الناتجة من الخطين إذا أخذنا بقيم الانحراف المعياري المقدمة من قبل المصنع، ومرة أخرى إذا تجاهلنا قيم الانحراف المقدمة من قبل المصنع.

ج- هل تتوافق النتائج التي حصلنا عليها من العينات حول الانحراف المعياري مع ما قدمه المصدرين A و B وذلك عند مستوى من الثقة قدره 95%؟

د- إذا كان $n = 49$ و $m = 36$ ، فعند أي مستوى من الثقة يمكننا البت في أن متوسط قطر القضبان الناتج عن الخط الأول أكبر من متوسط قطر القضبان الناتج عن الخط الثاني؟

الفصل الحادي عشر

مدخل إلى اختبارات الفرضيات الإحصائية

AN INTRODUCTION TO STATISTICAL HYPOTHESES TESTES

(١١, ١) مفاهيم أساس لدراسة اختبار فرضية إحصائية

Based Concepts for Study a Statistical Hypothesis Test

لقد قدمنا في الفصل السابق فترات الثقة لمعالم مجتمع (طبيعي أو برنولي)، وقد لاحظنا أن هذه الفترات قد تساعدنا في بعض الحالات على إصدار قرار حول مقولة متعلقة بالمجتمع (وللتذكير نقصد بمجتمعاً إحصائياً دوماً). لكن الهدف الأساس من تلك الفترات كان تعيين الفترة التي تنتمي إليها معلمة المجتمع باحتمال معلوم، ومن ثم تنفيذ بعض العمليات المتعلقة بذلك مثل تعيين الخطأ الأعظمي المرتكب نتيجة أخذ قيمة إحصاءة مقدرة لمعلمة كقيمة بديلة لهذه المعلمة، وكذلك تعيين حجم العينة الذي يجب أن يستخدم بحيث لا يتجاوز الخطأ مقداراً محدداً مسبقاً. أما مسألة اتخاذ قرار حول قبول أو رفض مقولة متعلقة بالمجتمع المدروس (كأن تكون متعلقة بخاصية ما من خصائصه مثل: المتوسط، أو الانحراف المعياري، أو التوزيع، أو...) مع الأخذ بالحسبان مقدار احتمال رفضها وهي صحيحة، أو قبولها وهي خاطئة فإن ذلك يخرج عن إمكانيات فترات الثقة، والقطاع الإحصائي الذي يهتم بمثل هذه المسائل يعرف باسم اختبار الفرضيات الإحصائية.

في الواقع يُنظر إلى اختبارات الفرضيات الإحصائية على أنه أحد جوانب الاستدلال الإحصائي وركيزة أساس لنظرية اتخاذ القرار Decision-Making Theory، علماً أن الاستدلال الإحصائي ونظرية اتخاذ القرار يهتمان بشكل أساسي بالطرائق والتطبيقات المكونة للأحكام حول خصائص المجتمع معتمدة في ذلك على عينات (وللتذكير نقصد بها عينات عشوائية دوماً) مسحوبة من ذلك المجتمع. أكثر من ذلك، فإن اختبارات الفرضيات الإحصائية تهتم بإنجاز تلك العمليات التي تقوم على قبول أو رفض فرضية أو مقولة متعلقة بالمجتمع الذي قيد الدراسة معتمدة في ذلك على عينات مسحوبة من هذا المجتمع، فإذا كانت الفرضية التي تحت الاختبار تتعلق بمعلمة أو أكثر من معالم المجتمع المدروس، فعندئذ يدعى هذا الاختبار بـ اختبار معلمي Parametric Test، وأما إذا كانت الفرضية التي تحت الاختبار تتعلق بتوزيع المجتمع أو بخاصية ما مثل الاستقلال بين التوزيعات أو التجانس، فعندئذ يدعى مثل هذا الاختبار بـ اختبار غير معلمي Non Parametric Test.

في هذا الفصل سنقدم بعض الاختبارات المعلمية وأخرى غير المعلمية، وهذه الاختبارات تتطلب منا تقديم بعض المفاهيم المتعلقة باختبار الفرضيات، حيث سنستند في معلوماتنا المقدمة في هذا الفصل على المراجع الآتية من المراجع المذكورة في نهاية هذا الكتاب [6]، [20]، [24]، [33]، [43]، [45]، [47]، [55]، [62] و [63].

(١١, ١, ١) الفرضيات الإحصائية Statistical Hypotheses

إن أول ما يتبادر لذهن المرء هو معرفة ما تعنيه عبارة فرضية إحصائية، ولذلك سنبدأ بتقديم مجموعة من المفاهيم التي تخدم هذا المصطلح.

(١١, ١, ١, ١) تعريف (الفرضية الإحصائية)

إنَّ **الفرضية الإحصائية** هي مقولة أو إفادة تتعلق بالمجتمع المدروس، وهذه المقولة تحتل الصحة أو الخطأ.

(١١, ١, ١, ٢) ملاحظات

١- تجدر الإشارة هنا إلى أنَّ قبول الفرضية الإحصائية لا يعني بالضرورة أنَّها صحيحة، ولكن وفقاً لمعطيات العينة المسحوبة من المجتمع ليس لدينا ما يدفعنا إلى رفضها، في حين أنَّ رفض الفرضية الإحصائية إنما يعني الإقرار بخطئها حتماً.

٢- عادةً يضع المرء الفرضية التي يأمل أن تكون صحيحة موضعَ الرفض ويُطلق عليها اسم **الفرضية الابتدائية** Null Hypothesis (أو **الفرضية الصفرية-أو فرضية العدم**) ويرمز لها بـ H_0 ، وإذا ما توصل المرء **لنتيجة لمعطيات العينة المسحوبة من المجتمع** إلى رفض هذه الفرضية فإنه سيلجأ إلى قبول فرضية أخرى يُطلق عليها اسم **الفرضية البديلة** Alternative Hypothesis ويرمز لها عادةً بـ H_A ، والأمثلة الآتية توضح لنا ذلك.

(١١, ١, ١, ٣) أمثلة

١- لنأخذ تجربة إلقاء حجر نرد لمرة واحدة فقط، فعندئذ بفرض أنَّ p هو احتمال ظهور أية قيمة من القيم الست الممكنة للأعلى، فعندئذ بوضع $H_0: p = \frac{1}{6}$ ، فإنَّ ذلك يعني أنَّه لدينا اختبار للفرضية الابتدائية القائلة بتوازن حجر النرد، وفي حال التوصل إلى رفض هذه الفرضية **لنتيجة لمعطيات العينة** فإنه يجب القبول بفرضية أخرى بديلة $H_A: p \neq \frac{1}{6}$ أو $H_A: p > \frac{1}{6}$ أو $H_A: p < \frac{1}{6}$ وكلَّ منها تُعبر عن **عدم** توازن حجر نرد.

٢- لنأخذ تجربة إلقاء قطعة نقود معدنية لمرة واحدة فقط، فعندئذ بفرض p هو احتمال ظهور الصورة للأعلى، فعندئذ بوضع $H_0: p = \frac{1}{2}$ ، فإنَّ ذلك يعني أنَّه لدينا اختبار للفرضية الابتدائية القائلة بتوازن قطعة النقود، وفي حال التوصل إلى رفض هذه الفرضية فإنه يجب القبول بفرضية أخرى بديلة من أحد الأشكال الآتية وجميعها تُعبر عن **عدم** توازن قطعة النقود:

$$H_A: p \neq \frac{1}{2} \quad \text{or} \quad H_A: p > \frac{1}{2} \quad \text{or} \quad H_A: p < \frac{1}{2}$$

٣- لنفترض أنَّه لدينا مجتمعاً مكوناً من درجات الاختبار لطلاب السنة الأولى المشتركة في جامعة ما، فعندئذ لو وضعنا الفرضية الابتدائية:

$$H_0: F = N(\mu, \sigma)$$

فإنَّنا نأمل بذلك أن يكون لتوزيع درجات الطلاب توزيع طبيعي بمتوسط μ وانحراف معياري σ ، وفي حال التوصل إلى رفض هذه الفرضية فإنه يجب القبول بفرضية أخرى بديلة من الشكل الآتي:

$$H_A: F \neq N(\mu, \sigma)$$

نلاحظ من الأمثلة السابقة أنَّ اختيار الفرضية البديلة يتم بناءً على طبيعة المسألة المطروحة ومتطلباتها، ولا توجد قاعدة محدَّدة تفرض علينا مسبقاً شكلية الفرضية البديلة التي يجب أخذها إلاَّ إذا طلب ذلك صراحةً في نص المسألة المُعدَّة للدراسة.

(١١, ١, ٢) الأخطاء الناتجة عن دراسة فرضية إحصائية واحتمالاتها

نعلم أنَّ قيم الإحصاءات قد تتغير بتغير العينات المسحوبة من المجتمع، ومن ثمَّ قيمة إحصاءة مقدَّرة (كمقدَّر نقطي) للمعلَّمة مجتمع ما قد تكون قريبة من القيمة المتوقعة للمعلَّمة في حال صحة الفرضية الإحصائية المقدَّمة، وأمَّا إذا كان الفرق ما بين قيمة هذه الإحصاءة والقيمة المتوقعة للمعلَّمة كبيرة نسبياً، فعندئذ يُقال إنَّ الفرق ذو أهمية، ونتيجة لذلك تُرفض الفرضية الابتدائية H_0 ، ومن ثمَّ فإنه لدى قبول أو رفض فرضية إحصائية قد يرتكب خطأ ما، وهذا الخطأ على نوعين هما:

الخطأ من النوع الأول Error of the First Type

إنَّ الخطأ من النوع الأول (ويعرف باسم **Type I Error** أيضاً) هو ذلك الخطأ الناشئ عن رفض الفرضية الابتدائية H_0 على الرغم من صحتها.

الخطأ من النوع الثاني Error of the Second Type

إنَّ الخطأ من النوع الثاني (ويعرف باسم **Type II Error** أيضاً) هو ذلك الخطأ الناشئ عن قبول الفرضية الابتدائية H_0 على الرغم من خطئها.

إنَّ الوقوع في أي من الخطأين السابقين ممكن باحتمال ما، ولذلك تمَّ تخصيص قيم هذين الاحتمالين بأسماء خاصة بهما ويقدمهما لنا التعريفين الآتيين.

(١, ٢, ١) تعريف (مستوى أهمية الاختبار Significance Level of the Test)

يُطلق على قيمة احتمال الوقوع في الخطأ من النوع الأول اسم **مستوى أهمية الاختبار** (أو المخاطرة - أو المجازفة - من النوع الأول **The Risk of Type I**)، ويرمز لهذه القيمة بـ α .

(١, ٢, ٢) تعريف (المخاطرة من النوع الثاني The Risk of Type II)

يُطلق على قيمة احتمال الوقوع في الخطأ من النوع الثاني اسم **المخاطرة من النوع الثاني**، ويرمز لهذه القيمة بـ β .

(١, ٢, ٣) ملاحظات

١- يُطلق على مستوى أهمية اختبار فرضية إحصائية اسم **مستوى دلالة الاختبار** أيضاً، وأما في دراستنا المقبلة فإننا سنستخدم عبارة **مستوى الأهمية فقط**.

٢- يسعى المرء عادةً إلى جعل قيمة α صغيرة، وقد اتفق على أن أخذ $\alpha = 0.05$ مقبولة إحصائياً؛ ولذلك نرى أن معظم البرامج الإحصائية تنطلق من هذه القيمة لـ α كقيمة افتراضية، ولكن يمكن للمرء التعديل على هذه القيمة حسب متطلبات المسألة المدروسة.

٣- يُطلق على المقدار $1 - \beta$ اسم **قوة الاختبار** (أو حساسية الاختبار) **Power of the Test**.

٤- يُطلق على المقدار $1 - \alpha$ اسم **مستوى ثقة الاختبار** (أو احتمال الأمان)، حيث سنعتمد تسمية مستوى ثقة الاختبار، وهذه التسمية قد ورد ذكرها في الفصل السابق عند دراسة فترات الثقة.

٥- يمكن التعبير عن الثابتين α و β بوساطة الاحتمالات الشرطية أيضاً، وذلك على النحو الآتي:
بفرض أن $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمع موصوف من خلال متغير عشوائي X ، ولناخذ \mathcal{X}_n عينة من هذا المجتمع، وليكن $T = g(\mathcal{X}_n)$ مقدراً نقطياً للمعلّمة θ ، وأخيراً لنفترض أن C فترة من \mathbb{R} ، فعندئذ تكون C و \bar{C} تجزئة للمحور الحقيقي \mathbb{R} ، ولنصطلح على الآتي:

أ- نقبل الفرضية الابتدائية H_0 إذا كانت قيمة الإحصاء T تقع في الفترة C ، ومن ثمَّ رفض H_0 وفي هذه الحالة يُطلق على المنطقة التي تشغلها C اسم **منطقة القبول** Acceptance Area للفرضية الابتدائية.


ب- نقبل الفرضية البديلة H_A إذا كانت قيمة الإحصاء T تقع في \bar{C} ، ومن ثمَّ رفض H_0 ، وفي هذه الحالة يُطلق على المنطقة التي تشغلها \bar{C} اسم **منطقة الرفض** Rejection Area للفرضية الابتدائية (أو المنطقة الحرجة للاختبار **Critical Region of the Test**).

بناءً على ما تقدّم يمكننا أن نكتب ما يلي:

$$P(T \in C | H_0 \text{ is false}) = \beta \quad [11,1]$$

$$P(T \in \bar{C} | H_0 \text{ is true}) = \alpha \quad [11,2]$$

ولتوضيح العلاقة بين القيمتين α و β سنفترض (على سبيل التوضيح والتبسيط) أن للإحصاء T توزيعاً طبيعياً بدالة كثافة احتمالية $h(t; \theta)$ ، ولنأخذ الاختبار الإحصائي $H_0: \theta = \theta_0 \leq \bar{\theta}$ مقابل الفرضية البديلة $H_A: \theta = \theta_1 > \bar{\theta}$ ، علماً أن قيمة $\bar{\theta}$ مثبتة وتدعى **القيمة الحرجة** Critical Value أو **النقطة الحرجة** Critical Point للاختبار، فعندئذ يكون للإحصاء T تحت الفرضية الابتدائية H_0 دالة كثافة احتمالية $h(t; \theta_0)$ ، وتحت الفرضية البديلة H_A له دالة كثافة احتمالية $h(t; \theta_1)$ ، وهنا نلاحظ أن الدالة $h(t; \theta_1)$ تنتج عن $h(t; \theta_0)$ بانسحاب مقداره $\theta_1 - \theta_0$ لأن t ثابتة في هذه الحالة (انظر الشكل الآتي).



الشكل (١١, ١)

إن السؤال الذي يطرح نفسه هنا هو: ماذا نشترط من اختبار إحصائي ما؟

في الواقع ما يطمح إليه المرء لدى اختبار إحصائي ما هو معرفة قيمة الإحصاء T التي من أجلها تكون الفرضية الابتدائية H_0 مقبولة، وهذا يعني أنه من أجل أية قيمة للعين \mathcal{X}_n علينا أن نعطي منطقة قبول ومنطقة رفض للفرضية الابتدائية H_0 . لذلك ستكون المهمة مركزة على كيفية اختيار النقاط على محور المعلمة θ (في دراستنا هذه هو المحور الحقيقي نفسه) التي تحدّد لنا منطقة القبول ومنطقة الرفض للفرضية الابتدائية H_0 التي من أجلها يكون قرار القبول أو الرفض صحيحاً باحتمال معلوم، ولتوضيح ذلك أكثر سنفترض أن $\bar{\theta}$ هي تلك النقطة التي تفصل منطقة القبول C عن منطقة الرفض \bar{C} للفرضية H_0 ، ولذلك دُعيت $\bar{\theta}$ **النقطة الحرجة** (انظر الشكل السابق (١١, ١))، علاوة على ذلك سنفترض أنه من معطيات العينة \mathcal{X}_n حصلنا على قيمة t' للإحصاء T بحيث إن $t' < \bar{\theta}$ ، أي إن $t' \in \bar{C}$ ، فعندئذ تكون الفرضية الابتدائية H_0 مرفوضة، ولكن هذا القرار قد يكون غير صحيح لأن القيمة t' يمكن أن نحصل عليها عندما تكون $\bar{\theta} \leq \theta$ أيضاً، ومن ثم يكون لدينا ما يلي:


$$\alpha = P(T \in \bar{C} | H_0 \text{ is true}) = \int_{\bar{\theta}}^{\infty} h(t; \theta_0) dt \geq \int_{\bar{\theta}}^{\infty} h(t'; \theta_0) dt' \quad [11,3]$$

$$\beta = P(T \in C | H_0 \text{ is false}) = \int_{-\infty}^{\bar{\theta}} h(t; \theta_1) dt = 1 - \int_{\bar{\theta}}^{\infty} h(t; \theta_1) dt \quad [11,4]$$

وهكذا يلاحظ أنه من أجل حجم عينة مثبت (ومن ثم نفترض $h(t; \theta)$ ثابت)، فإن أي زيادة في قيمة α سيرافقها نقصان في قيمة β والعكس صحيح أيضاً (انظر الشكل السابق (١١, ١)). من جانب آخر نلاحظ أن α هي أكبر قيمة احتمال تكون من أجلها H_0 مرفوضة، ولهذا السبب فكلما كان مستوى الأهمية α أصغر أدى ذلك إلى اختبار أفضل للفرضية الابتدائية H_0 ، ولكن كما ذكرنا قبل قليل أنه في معظم الحالات يكون الاختبار مقبولاً إحصائياً عند مستوى من الأهمية قدره $\alpha \geq 0.05$ ، وهذا غالباً ما يستخدم في التطبيقات العملية.

الآن لننظر ما الذي سيحصل عندما نزيد حجم العينة؟

إذا قمنا بزيادة حجم العينة \mathcal{X}_n على ما كانت عليه سابقاً، فعندئذ تبين الإحصاءة T سوف يتناقص، وذلك لأن تبين هذه الإحصاءة متناسب عكساً مع حجم العينة (بحسب توزيعات المعاينة التي درسناها سابقاً)، ومن ثم فإن دالة الكثافة لهذه الإحصاءة سوف تصبح أكثر تدبياً وأطرافها أقل انبساطاً (انظر الشكل الآتي)، وبالتالي ينتج عنه تناقض في قيمتي σ و β معاً من أجل قيمة مُثبتة لـ $\bar{\theta}$.



الشكل (١١, ٢) قارن هذا العرض مع الشكل (١١, ١)

الجدول الآتي يقدم لنا القرارات المتخذة لدى اختبار إحصائي ما:

الجدول (١١, ١)

اتخاذ القرار		نتيجة القرار		احتمال نتيجة القرار يساوي	
الحال الحقيقي للفرضية	H ₀ صحيحة	H ₀ مقبولة	قرار صحيح	1 - α	مستوى ثقة الاختبار
		H _A مرفوضة			
	H ₀ خاطئة	H ₀ مرفوضة	قرار خاطئ	α	مستوى الأهمية (أو المخاطرة من النوع الأول)
		H _A مقبولة	(خطأ من النوع الأول)		
		H ₀ مقبولة	قرار خاطئ	β	(أو المخاطرة من النوع الثاني)
		H _A مرفوضة	(خطأ من النوع الثاني)	1 - β	قوة الاختبار
		H _A مقبولة	قرار صحيح		

(١١, ٢, ٤) ملاحظات

١- بما أننا نهتم عادة بعدم الرفض الخاطئ لفرضية إحصائية، فإنه علينا أن نأخذ الفرضية الابتدائية بحيث يكون احتمال رفضها على الرغم من صحتها صغيراً، وغالباً يؤخذ احتمال رفضها بحيث يكون أصغر أو يساوي 0.05.

٢- من أجل اختبار مُحَدَّد وعينة مُثبتة الحجم لا يمكن تصغير α و β معاً، ولكن يمكننا أن نُصَغِّرَ قيمة α بالقدر الذي نريد عندما لا نكون مهتمين بقيمة β .

٣- بتكبير حجم العينة n نستطيع تصغير كل من α و β معاً، ومن ثم تحسين قوة الاختبار $1 - \beta$.

لقد ذكرنا سابقاً أنه يمكن تصنيف الفرضيات الإحصائية إلى نوعين أساسيين هما الاختبارات **المعلمية** (أي عندما يكون الاختبار

متعلق بمَعَالِم المجتمع) و الاختبارات غير المُعلِّمة (أي عندما يكون الاختبار متعلق بأي شيء يخص المجتمع عدا معالِمه). أكثر من ذلك سنلاحظ فيما يلي أنَّ اختبارات الفرضيات الإحصائية المُعلِّمة يمكن أن تصنّف في نوعين رئيسيين أيضاً يقدمهما لنا التعريفين الآتيين.

(١١, ١, ٢, ٥) تعريف (الفرضية المركبة Composite hypothesis)

ليكن $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X ، ولناخذ \mathcal{X}_n عينة من هذا المجتمع، فإذا كان اختبار الفرضية الابتدائية من النموذج $H_0: \theta \in \Theta_0$ مقابل فرضية بديلة من النموذج $H_A: \theta \notin \Theta_0$ علماً أنَّ $\mathbb{R}^k \supseteq \Theta \supseteq \Theta_0$ و $N \ni k$ ، فعندئذ يُقال إنَّ لدينا اختبار فرضية مركبة.

(١١, ١, ٢, ٦) تعريف (الفرضية البسيطة Simple hypothesis)

ليكن $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X ، ولناخذ \mathcal{X}_n عينة من هذا المجتمع، فإذا كان اختبار الفرضية الابتدائية من النموذج $H_0: \theta = \theta_0$ مقابل فرضية بديلة من أحد النماذج الآتية:

$$H_A: \theta \neq \theta_0 \quad \text{or} \quad H_A: \theta > \theta_0 \quad \text{or} \quad H_A: \theta < \theta_0$$

فعندئذ يُقال إنَّ لدينا اختبار فرضية بسيطة.

(١١, ١, ٢, ٧) ملاحظة

إذا كانت $\mathbb{R}^k \supseteq \Theta \ni \theta$ ، وبفرض أنَّ الاختبار متعلق ببعض مركبات المتجه $\theta = (\theta_1, \theta_2, \dots, \theta_k)$ فإنَّ بقية المركبات التي لم يشملها الاختبار تُدعى مَعَالِم مشوشة Perturbation Parameters.

(١١, ١, ٢, ٨) أمثلة

١- ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً بواسونياً بمَعْلَمَة λ ، $0 < \lambda$ ، فإذا أخذنا الفرضية الابتدائية $H_0: \lambda = 2$ مقابل إحدى الفرضيات البديلة $H_A: \lambda \neq 2$ أو $H_A: \lambda > 2$ أو $H_A: \lambda < 2$ ، ونكون عندئذ أمام فرضية بسيطة (ليس فيها مَعَالِم مشوشة).

٢- ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً حدانياً بمَعْلَمَتين n و p ، فإذا أخذنا الفرضية الابتدائية $H_0: p = 0.5$ مقابل إحدى الفرضيات البديلة $H_A: p \neq 0.5$ أو $H_A: p > 0.5$ أو $H_A: p < 0.5$ ، ونكون عندئذ أمام اختبار لفرضية بسيطة فيها المَعْلَمَة n هي مَعْلَمَة مشوشة.

٣- ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً طبيعياً بمتوسط μ وانحراف معياري σ ، فإذا أخذنا الفرضية الابتدائية $H_0: \mu < 5$ التي تكافئ الفرضية الابتدائية $H_0: (\mu, \sigma) \in (-\infty, 5) \times (0, \infty)$ مقابل الفرضية البديلة $H_A: \mu \geq 5$ التي تكافئ الفرضية البديلة $H_A: (\mu, \sigma) \in [5, \infty) \times (0, \infty)$ ، فإنَّنا سنكون أمام اختبار لفرضية مركبة.

(١١, ١, ٢, ٩) ملاحظات


١- إذا كان لدينا اختبار لفرضية ابتدائية من النموذج $H_0: \theta = \theta_0$ مقابل فرضية بديلة من النموذج $H_A: \theta \neq \theta_0$ ، فعندئذ يُقال إنَّ لدينا اختبار ثنائي الطرف (أو ثنائي الذيل) Two-Tailed Test، وأما إذا كانت الفرضية البديلة من النموذج $H_A: \theta > \theta_0$ أو $H_A: \theta < \theta_0$ ، فعندئذ يُقال إنَّ لدينا اختبار أحادي الطرف (أو أحادي الذيل) One-Tailed Test.

٢- في هذا الفصل من الكتاب لن نقوم بدراسة الفرضيات المركبة.

(١١, ١, ٣) تعيين منطقة الرفض المثلى للفرضية الابتدائية

Determination the Optimum Rejection Area of Primary Hypothesis

لقد لاحظنا خلال توضيحنا للمقدارين α و β أننا اخترنا نموذجاً لاختبار وحيد الطرف، وقد كانت المساحة التي تُحدد منطقة الرفض (وقدراها α) تقع في جهة واحدة، وبالتالي من أجل حجم عينة مُثبت ستكون منطقة الرفض مُحَدَّدة تماماً. لكن لو كان لدينا اختبار ثنائي الطرف، فعندئذ ستكون هذه المساحة الممثلة لمنطقة الرفض مجزأة على طرفي دالة الكثافة الاحتمالية بحيث يكون عند الطرف الأيسر مساحة قدرها α_1 وعند الطرف الأيمن مساحة قدرها α_2 وبحيث يكون $\alpha_1 + \alpha_2 = \alpha$ ، أي سيكون لدينا أحد العروض الموجودة في الشكل الآتي (١١, ٣) (وجميعها تعالج الاختبار نفسه).



الشكل (١١, ٣)

فلاحظ إمكانية وجود أكثر من منطقة رفض ناتجة عن القيمة α نفسها، ومن ثمَّ منطقة القبول للفرضية الابتدائية H_0 قد تطول حيناً وتقصّر حيناً آخر، ولذلك يطرح السؤال الآتي:

أي من هذه المناطق سنختار كم منطقة قبول للفرضية الابتدائية؟

نُعطينا النظرية الآتية (التي سنقبلها دون برهان) أفضل منطقة رفض للفرضية الابتدائية $H_0: \theta = \theta_0$ مقابل الفرضية البديلة $H_A: \theta \neq \theta_0$.

(١١, ١, ٣, ١) نظرية (نيان – بيرسون Neyman Pearson Theorem)

ليكن $[\Omega, \mathcal{S}, \mathcal{P} = \{P_\theta; \theta \in \Theta\}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X ، ولنأخذ عينة من هذا المجتمع، ولنفترض أننا نريد اختبار فرضية ابتدائية $H_0: \theta = \theta_0$ مقابل فرضية بديلة $H_A: \theta \neq \theta_0$ عند مستوى من الأهمية قدره α . تحت هذه الفرضيات تُعطى منطقة الرفض المثلى Optimal Rejection Area (وسنرمز لها بـ C^*) للفرضية الابتدائية H_0 من خلال المجموعة الآتية:

$$C^* = \left\{ \bar{x}_n ; \frac{L(\bar{x}_n; \theta_1)}{L(\bar{x}_n; \theta_0)} \geq k \right\} \quad [11,5]$$

علماً أن $L(\bar{x}_n; \theta)$ هي دالة الأرجحية للعينة \mathcal{X}_n ومُعطاة بالعلاقة [10-2]، وأما \bar{x}_n فهي قيمة الملاحظة للعينة \mathcal{X}_n ، وأخيراً $0 < k$ ثابت يُعيّن من خلال العلاقة الآتية:

$$P(\mathcal{X}_n \in C^* | H_0 \text{ is true}) = \alpha \quad [11,6]$$

(١١, ١, ٣, ٢) ملاحظة

إن الاختبار الذي يعتمد على منطقة رفض مثلى وفقاً لنظرية نيان – بيرسون يُدعى أفضل اختبار Best Test أو الاختبار

الأمثل Optimal Test ، ويبرهن في هذه الحالة أن أقصر طول للفترة التي تُعَيَّن منطقة القبول للفرضية الابتدائية H_0 والموافقة لأصغر خطأ من النوع الثاني β هي الفترة التي يقع على يمينها $\frac{\alpha}{2}$ وعلى يسارها $\frac{\alpha}{2}$ من مساحة حجم منطقة الرفض.

(١١, ١, ٣, ٣) مثال

ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً طبيعياً بمتوسط μ وانحراف معياري $\sigma = \sigma_0$ معلوم، ولنأخذ \mathcal{X}_n عينة من هذا المجتمع، ولنقم بتحديد منطقة الرفض المثلى للفرضية الابتدائية $H_0: \mu = \mu_0$ مقابل الفرضية البديلة $H_A: \mu = \mu_1 \neq \mu_0$ ، وذلك عند مستوى من الأهمية قدره α .

الحل: نعلم أن دالة الأرجحية لعينة عشوائية \mathcal{X}_n مسحوبة من مجتمع طبيعي لها العرض الآتي:

$$L(\bar{x}_n; (\mu, \sigma_0)) = \left(\frac{1}{2\pi\sigma_0^2} \right)^{\frac{n}{2}} \cdot \exp \left[-\frac{1}{2\sigma_0^2} \sum_{k=1}^n (x_k - \mu)^2 \right]$$

ومن أجل $\mu_1 \neq \mu_0$ يكون لدينا ما يلي:

$$\frac{L(\bar{x}_n; (\mu_1, \sigma_0))}{L(\bar{x}_n; (\mu_0, \sigma_0))} = \exp \left[\frac{\mu_1 - \mu_0}{\sigma_0^2} \sum_{k=1}^n x_k + \frac{n(\mu_0^2 - \mu_1^2)}{2\sigma_0^2} \right]$$

ومن ثمَّ نحدد منطقة الرفض المثلى C^* لهذا الاختبار من خلال العلاقة الآتية:

$$C^* = \left\{ \bar{x}_n ; \exp \left[\frac{\mu_1 - \mu_0}{\sigma_0^2} \sum_{k=1}^n x_k + \frac{n(\mu_0^2 - \mu_1^2)}{2\sigma_0^2} \right] \geq k \right\}$$

علماً أن k ثابت يجب تعيينه، ومن أجل ذلك سنقدّم المناقشة الآتية:

بما أن $\mu_1 \neq \mu_0$ ، فعندئذٍ يمكننا أن نفترض أن $\mu_1 > \mu_0$ ، ومنه سيكون وفقاً لمعطيات المجموعة C^* ما يلي مُحَقَّقاً:

$$\sum_{k=1}^n x_k \geq \frac{\sigma_0^2 \ln k}{\mu_1 - \mu_0} + \frac{n(\mu_1 + \mu_0)}{2} \triangleq a \quad (1)$$

فلاحظ أن $a \in \mathbb{R}$ وذلك لأن $k \in (0, \infty)$ ، ومن ثمَّ يصبح لـ C^* العرض $C^* = \left\{ \bar{x}_n ; \sum_{k=1}^n x_k \geq a \right\}$ ، ولنقم بتعيين القيمة a بحيث تكون العلاقة [11,6] مُحَقَّقَةً، حيث لدينا:

$$P(\mathcal{X}_n \in C^* | H_0 \text{ is true}) = P(\mathcal{X}_n \in C^* | \mu = \mu_0) = \alpha$$

وباستخدام العلاقة (1) يمكننا أن نكتب الآتي:

$$\begin{aligned} \alpha &= P(\mathcal{X}_n \in C^* | \mu = \mu_0) = P\left(\sum_{k=1}^n x_k \geq a \mid \mu = \mu_0\right) = P(n \cdot \bar{X} \geq a \mid \mu = \mu_0) \\ &= P\left(\bar{X} \geq \frac{a}{n} \mid \mu = \mu_0\right) = P\left(\frac{\bar{X} - \mu_0}{\frac{\sigma_0}{\sqrt{n}}} \geq \frac{\frac{a}{n} - \mu_0}{\frac{\sigma_0}{\sqrt{n}}}\right) \end{aligned}$$

والآن بوضع $Z := \frac{\bar{X} - \mu_0}{\frac{\sigma_0}{\sqrt{n}}} \sqrt{n}$ وكذلك $c := \frac{\frac{a}{n} - \mu_0}{\frac{\sigma_0}{\sqrt{n}}} \sqrt{n}$ ينتج لدينا أن $P(Z \geq c) = \alpha$ ، ومن ثمَّ يكون لدينا

وبما أن $Z \sim N(0,1)$ ، فإنه سيكون لـ c القيمة $c = z_{1-\alpha}$ ، ومن ثم ينتج أن قيمة a تساوي:

$$a = n \cdot \mu_o + z_{1-\alpha} \sigma_o \sqrt{n}$$

وهكذا يصبح لـ k القيمة الآتية:

$$k = \exp \left[\frac{\mu_1 - \mu_2}{\sigma_o^2} \cdot a - \frac{n \cdot (\mu_1^2 - \mu_o^2)}{2 \sigma_o^2} \right]$$

ومنه يكون للمنطقة C^* العرض الآتي:

$$C^* = \left\{ \bar{x}_n ; \sum_{k=1}^n x_k \geq \alpha = n \cdot \mu_o + z_{1-\alpha} \sigma_o \sqrt{n} \right\}$$

الآن، وبشكل مماثل لما سبق نجد أنه إذا كان $\mu_o > \mu_1$ فإن منطقة الرفض المثلى الموافقة لمستوى أهمية قدره α سيكون لها العرض الآتي:

$$C^* = \left\{ \bar{x}_n ; \sum_{k=1}^n x_k \leq \alpha = n \cdot \mu_o + z_{1-\alpha} \sigma_o \sqrt{n} \right\}$$

أخيراً إذا كان $\mu_1 \neq \mu_o$ دون تحديد أي من μ_1 و μ_o هو أصغر من الآخر، فإن منطقة الرفض المثلى الموافقة لمستوى أهمية قدره α سيكون لها العرض الآتي:

$$C^* = \left\{ \bar{x}_n ; \sum_{k=1}^n x_k \leq \alpha = n \cdot \mu_o + z_{1-\frac{\alpha}{2}} \sigma_o \sqrt{n} \right\} \cup \left\{ \bar{x}_n ; \sum_{k=1}^n x_k \geq \alpha = n \cdot \mu_o + z_{1-\frac{\alpha}{2}} \sigma_o \sqrt{n} \right\}$$

وذلك لأن منطقة الرفض في هذه الحالة تكون منطقة معينة بالمتباينتين $-z_{1-\frac{\alpha}{2}} \leq z$ و $z_{1-\frac{\alpha}{2}} \leq z$ ، وهاتين العلاقتين تعطيان أقصر طول للفترة التي تُعين منطقة القبول للفرضية الابتدائية $H_o: \mu = \mu_o$.

(١١، ١، ٣، ٤) ملاحظة

عندما يرد ذكر منطقة الرفض لفرضية ابتدائية H_o إننا نعني بذلك منطقة الرفض المثلى دون الخوض في إثبات ذلك.

(١١، ٢) الاختبارات الإحصائية من أجل معلمتي مجتمع طبيعي

Statistical Tests for Parameters of Normal Population

فيما يلي سنركز دراستنا على الاختبارات المعلمية لمجتمعات طبيعية (أو طبيعية على وجه التقريب حيث سنفترضها طبيعية أيضاً)، ومن أجل ذلك ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X خاضع للتوزيع $N(\mu, \sigma)$ ، ولناخذ عينة من \mathcal{X}_n عينة من هذا المجتمع بمتوسط \bar{x} وانحراف معياري s ، وعلى سبيل التذكير فإن \bar{x} و s هما قيمتي الإحصاءتين \bar{X} و S على الترتيب.


(١١، ٢، ١) اختبارات من أجل متوسط مجتمع طبيعي

تقدم لنا المبرهنات الآتية (سنقبلها دون برهان) اختبارات الفرضيات المتعلقة بـ μ متوسط المجتمع الطبيعي.

(١, ١, ٢, ١١) مبرهنة

تحت الفرضيات المقدّمة آنفاً وبفرض أن الانحراف المعياري للمجتمع $\sigma = \sigma_0$ معلوماً، وأنّه لدينا الفرضية الابتدائية $H_0: \mu = \mu_0$ ، فعندئذ:

١- إذا كانت الفرضية البديلة هي $H_A: \mu \neq \mu_0$ ، فإنّ منطقة الرفض للفرضية الابتدائية H_0 وعند مستوى من الأهمية قدره α تكون معيّنة بالمنطقة المحددة بالمتباينة $|z| \geq z_{1-\frac{\alpha}{2}}$ (انظر الشكل الآتي).




الشكل (٤, ١١, أ)

علماً أنّ z تُحسب بالعلاقة الآتية:

$$z = \frac{\bar{X} - \mu_0}{\sigma_0} \sqrt{n}$$


[11,7]

٢- إذا كانت الفرضية البديلة هي $H_A: \mu < \mu_0$ ، فإنّ منطقة الرفض للفرضية الابتدائية H_0 وعند مستوى من الأهمية قدره α تكون معيّنة بالمنطقة المحددة بالمتباينة $z \leq -z_{1-\alpha}$ علماً أنّ z تُحسب بالعلاقة السابقة [11,7] (انظر الشكل الآتي).



الشكل (٤, ١١, ب)

٣- إذا كانت الفرضية البديلة هي $H_A: \mu > \mu_0$ ، فإنّ منطقة الرفض للفرضية الابتدائية H_0 وعند مستوى من الأهمية قدره α تكون معيّنة بالمنطقة المحددة بالمتباينة $z \geq z_{1-\alpha}$ علماً أنّ z تُحسب بالعلاقة السابقة [11,7] (انظر الشكل الآتي).



الشكل (٤, ١١, ج)


(١١, ٢, ١, ٢) مبرهنة

تحت الفرضيات المقدّمة آنفاً وبفرض أن الانحراف المعياري للمجتمع مجهولاً (أي إن $\sigma = ?$)، وأنه لدينا الفرضية الابتدائية $H_0: \mu = \mu_0$ ، فعندئذ:

١- إذا كانت الفرضية البديلة هي $H_A: \mu \neq \mu_0$ ، فإن منطقة الرفض للفرضية الابتدائية H_0 وعند مستوى من الأهمية α تُعَيَّن بالمنطقة المحددة بالمتباينة $|t| \geq t_{1-\frac{\alpha}{2}}^{n-1}$ (انظر الشكل الآتي) علماً أن t تُحسب بالعلاقة الآتية:


$$t = \frac{\bar{x} - \mu_0}{s} \sqrt{n}$$

[11,8]




الشكل (١١, ٥) أ

٢- إذا كانت الفرضية البديلة هي $H_A: \mu < \mu_0$ ، فإن منطقة الرفض للفرضية الابتدائية H_0 وعند مستوى من الأهمية α تُعَيَّن بالمنطقة المحددة بالمتباينة $t \leq -t_{1-\alpha}^{n-1}$ (انظر الشكل الآتي) علماً أن قيمة t تُحسب بالعلاقة السابقة [11,8].



الشكل (١١, ٥) ب

٣- إذا كانت الفرضية البديلة هي $H_A: \mu > \mu_0$ ، فإن منطقة الرفض للفرضية الابتدائية H_0 وعند مستوى من الأهمية α تُعَيَّن بالمنطقة المحددة بالمتباينة $t \geq t_{1-\alpha}^{n-1}$ (انظر الشكل الآتي) علماً أن t تُحسب بالعلاقة السابقة [11,8].



الشكل (١١, ٥) ج

(١١, ٢, ١, ٣) مثال

زعم مصنع لإنتاج بطاريات 3.7 فولت للهواتف المحمول أن متوسط عمل البطاريات لديه بعد شحنها بنسبة 100% وعند سحب تيار ثابت قدره 20 ميلي أمبير يساوي 72 ساعة بانحراف معياري قدره σ_o ساعة، قمنا بأخذ عينة من إنتاج هذا المصنع بحجم n بطارية فوجدنا أن متوسط عمل هذه البطاريات وتحت الفرضيات المذكورة آنفاً يساوي 70 ساعة بانحراف معياري قدره 4 ساعات، فإذا افترضنا أن أعمار شحن البطاريات يخضع للتوزيع الطبيعي، فندتد من أجل مستوى أهمية قدره $\alpha = 0.05$ لنقم بما يلي:

١- اختبار الفرضية القائلة إن متوسط عمل البطارية يساوي 72 ساعة تحت الفرضيات المذكورة آنفاً علماً أن $\sigma_o = 5$ ساعات و $n = 36$.

٢- إعادة حل الطلب السابق إذا كان مستوى الأهمية $\alpha = 0.01$.

٣- اختبار الفرضية القائلة إن متوسط عمل البطارية يساوي 72 ساعة وتحت الفرضيات المذكورة آنفاً علماً أن الانحراف المعياري $\sigma_o = ?$ مجهولاً و $n = 49$.

٤- حساب قيمة β (احتمال الوقوع في الخطأ من النوع الثاني) إذا كان متوسط العمل الحقيقي للبطاريات يساوي 70 ساعة وبانحراف معياري $\sigma_o = 2$ ساعة، وكان:

أ- حجم العينة $n = 9$.

ب- حجم العينة $n = 36$.

ولنلاحظ ما الذي سيحدث لقيمة قوة الاختبار $1 - \beta$ ؟

الحل: من أجل الطلب:

١- للرد على زعم المصنع علينا اختبار الفرضية الابتدائية $H_o: \mu = \mu_o = 72$ وذلك عند مستوى الأهمية $\alpha = 0.05$ ، وأما الفرضية البديلة فيمكننا اختيارها وفقاً لأحد النموذجين $H_A: \mu \neq \mu_o = 72$ أو $H_A: \mu < \mu_o = 72$ ، وذلك لأنه من معطيات العينة لدينا متوسط أعمار هذه البطاريات في العينة يساوي $\mu_o = 70 < 72$ ، وفي مثل هذه الدراسات يرجح أخذ الفرضية البديلة $H_A: \mu < \mu_o$ لأن معطيات العينة تثير في نفسنا الشك تجاه حالة المساواة، وبالتالي من أجل هذه المسألة تكون نتيجة الاختبار المبينة على الاختيار $H_A: \mu < \mu_o$ أكثر دقة.

الآن، وبما أن $\sigma_o = 5$ فهذا يعني أن الانحراف المعياري معلوماً، فإنه من أجل الاختيار $H_o: \mu = \mu_o = 72$ لدينا من جدول

التوزيع الطبيعي $z_{1-\frac{\alpha}{2}} = z_{0.975} = 1.96$ ، وأما لحساب قيمة Z علينا استخدام العلاقة [11,7] حيث لدينا:

$$z = \frac{\bar{x} - \mu_o}{\sigma_o} \sqrt{n} = \frac{70 - 72}{5} \sqrt{36} = -2.40$$

ومن ثم ينتج لدينا أن $z = -2.40 < -1.96 = -z_{1-\frac{\alpha}{2}}$ ، وهكذا نجد أن قيمة Z تقع في منطقة الرفض للفرضية الابتدائية H_o ، وبالتالي نرفض ادعاء المصنع حول متوسط زمن التشغيل للبطاريات عند مستوى الأهمية $\alpha = 0.05$.

أما من أجل الفرضية البديلة $H_A: \mu < \mu_o = 72$ نلاحظ أن $z_{1-\alpha} = z_{0.95} = 1.645$ ، ومنه يكون لدينا:

$$z = -2.40 < -1.645 = -z_{1-\alpha}$$

ومن ثم نحصل على القرار السابق نفسه أيضاً.

٢- من أجل الفرضية البديلة $H_A: \mu \neq \mu_o = 72$ يكفي أن نعين قيمة $z_{1-\frac{\alpha}{2}} = z_{0.995} = 2.575$ فنجد أنها تساوي

ومنه يكون لدينا:

$$-z_{1-\frac{\alpha}{2}} = -2.575 < z = -2.40 < 2.575 = z_{1-\frac{\alpha}{2}}$$

وهكذا نجد أن قيمة z تقع في منطقة القبول للفرضية الابتدائية H_0 ، وبالتالي نقبل ادعاء المصنع حول متوسط زمن تشغيل البطاريات عند مستوى الأهمية $\alpha = 0.01$.

أما لو كنا قد أخذنا الفرضية البديلة $H_A: \mu < \mu_0 = 72$ فإنه سيكون $z_{1-\alpha} = z_{0.99} \approx 2.33$ ، ومنه يكون لدينا:

$$z = -2.40 < -2.33 = -z_{1-\alpha}$$

فنحصل من أجل هذه الحالة على قرار مختلف عن السابق حيث يكون قرارنا بالرفض في هذه الحالة عند مستوى الأهمية $\alpha = 0.01$.

٣- من أجل هذا الطلب علينا اختبار الفرضية الابتدائية $H_0: \mu = \mu_0 = 72$ عند مستوى الأهمية $\alpha = 0.05$ ، وأما الفرضية البديلة فيمكننا اختيارها وفقاً لأحد لنموذجين $H_A: \mu \neq \mu_0 = 72$ أو $H_A: \mu < \mu_0 = 72$ ، ولكن في هذه الحالة لدينا الانحراف المعياري للمجتمع σ^2 مجهولاً و $n = 49$ ، ولذلك علينا حساب قيمة t من خلال العلاقة [11,8] حيث لدينا:

$$t = \frac{\bar{x} - \mu_0}{s} \sqrt{n} = \frac{70 - 72}{4} \sqrt{49} = -3.50$$

ولذلك من أجل الفرضية البديلة $H_A: \mu \neq \mu_0$ يجب حساب قيمة $t_{1-\frac{\alpha}{2}}^{[n-1]}$ من جدول توزيع ستودنت فنجد $t_{0.975}^{[48]} = 2.010$ ، ومن ثم يكون لدينا:

$$t = -3.50 < -2.010 = -t_{0.975}^{[48]}$$

وهذا يعني أن قيمة t تقع في منطقة الرفض لـ H_0 ، وبالتالي نرفض ادعاء المصنع حول متوسط زمن التشغيل للبطاريات عند مستوى الأهمية $\alpha = 0.05$.

أما من أجل الفرضية البديلة $H_A: \mu < \mu_0$ فإنه يجب حساب قيمة $t_{1-\alpha}^{[n-1]}$ من جدول توزيع ستودنت فنجد $t_{0.99}^{[48]} = 2.407$ ، ومن ثم يكون لدينا:

$$t = -3.50 < -2.407 = -t_{0.99}^{[48]}$$

وهذا يعني أن قيمة t تقع في منطقة الرفض للفرضية H_0 أيضاً، ومن ثم نرفض ادعاء المصنع حول متوسط زمن التشغيل للبطاريات أيضاً وذلك عند مستوى الأهمية $\alpha = 0.05$.

٤- لحساب قيمة β نعلم أن هذه القيمة هي احتمال قبول الفرضية الابتدائية $H_0: \mu = \mu_0 = 72$ علماً أنها خاطئة وذلك عند مستوى الأهمية α ، ومن جهة أخرى، فإن احتمال قبول الفرضية الابتدائية $H_0: \mu = 70$ عند مستوى من الأهمية α يساوي إلى المساحة التي تحت منحنى دالة الكثافة الاحتمالية لـ \bar{X} ، علماً أن $\bar{X} \sim N\left(\mu, \frac{\sigma_0}{\sqrt{n}}\right)$ فوق فترة الثقة الآتية:

$$CI = \left(\mu_0 - z_{1-\frac{\alpha}{2}} \frac{\sigma_0}{\sqrt{n}}, \mu_0 + z_{1-\frac{\alpha}{2}} \frac{\sigma_0}{\sqrt{n}} \right)$$

أ- فإذا كان حجم العينة $n = 9$ ، فإنه سيكون لفترة الثقة السابقة العرض الآتي:

$$\left(72 - 1.96 \frac{2}{\sqrt{9}}, 72 + 1.96 \frac{2}{\sqrt{9}} \right) = (70.693, 73.307)$$

ومن ثم يكون لدينا:

$$\beta = P(70.693 < \bar{X} < 73.307 | H_o : \mu = 72 \text{ is false}) = P(70.693 < \bar{X} < 73.307 | H_o : \mu = 70 \text{ is true})$$

$$= P\left(\frac{70.693 - 70}{2/3} < \frac{\bar{X} - 70}{2/3} < \frac{73.307 - 70}{2/3}\right)$$

والآن بوضع $Z = \frac{\bar{X} - 70}{2/3}$ ينتج لدينا الآتي:

$$\beta = P(1.04 < Z < 4.96) = P(Z < 4.96) - P(Z \leq 1.04) \approx 1 - 0.8508 = 0.1492$$

ومن ثم تكون قيمة قوة الاختبار هي $1 - \beta \approx 1 - 0.1492 = 0.8508$.

ب- أما إذا كان حجم العينة $n = 36$ ، فإنه سيكون لفترة الثقة السابقة العرض الآتي:

$$\left(72 - 1.96 \frac{2}{\sqrt{36}}, 72 + 1.96 \frac{2}{\sqrt{36}}\right) = (71.347, 72.953)$$

وبالتالي يكون لدينا:

$$\beta = P(71.347 < \bar{X} < 72.953 | H_o : \mu = 72 \text{ is false}) = P(71.347 < \bar{X} < 72.953 | H_o : \mu = 70 \text{ is true})$$

$$= P\left(\frac{71.347 - 70}{2/6} < \frac{\bar{X} - 70}{2/6} < \frac{72.953 - 70}{2/6}\right)$$

وبوضع $Z = \frac{\bar{X} - 70}{2/6}$ ينتج لدينا الآتي:

$$\beta = P(4.041 < Z < 8.859) = P(Z < 8.859) - P(Z \leq 4.041) \approx 1 - 1 = 0$$

ومن ثم تكون قيمة قوة الاختبار مساوية لـ $1 - \beta \approx 1$ ، وهكذا نلاحظ أن ازدياد حجم العينة أدى إلى تصغير قيمة β بشكل كبير ومن ثم تحسين قيمة قوة الاختبار بشكل ملحوظ.


(١١، ٢، ٢) اختبارات من أجل تباين مجتمع طبيعي

تقدم لنا المبرهنة الآتية (ستقبلها دون برهان) اختباراً لفرضيات متعلقة بتباين مجتمع طبيعي.


(١١، ٢، ٢، ١) مبرهنة

ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً إحصائياً موصوفاً من خلال متغير عشوائي X خاضع للتوزيع $N(\mu, \sigma)$ ولناخذ \mathcal{X}_n عينة من هذا المجتمع قيمة متوسطها \bar{X} وانحرافها المعياري s ، ولنفترض أن قيمة متوسط هذا المجتمع $\mu = \mu_o$ معلوماً. عندئذ من أجل مستوى من الأهمية قدره α تكون منطقة الرفض للفرضية الابتدائية $H_o : \sigma^2 = \sigma_o^2$ معينة بوساطة:

١- المتباينتين $\chi_{\frac{\alpha}{2}}^{[n-1]} \geq \chi$ و $\chi_{1-\frac{\alpha}{2}}^{[n-1]} \leq \chi$ إذا كانت الفرضية البديلة $H_A : \sigma^2 \neq \sigma_o^2$ (انظر الشكل الآتي).




٢- المتباينة $\chi^2 \leq \chi_{1-\alpha}^{[n-1]}$ إذا كانت الفرضية البديلة $H_A: \sigma^2 > \sigma_o^2$ (انظر الشكل الآتي).



الشكل (٦، ١١. ب)

٣- المتباينة $\chi^2 \geq \chi_{\alpha}^{[n-1]}$ إذا كانت الفرضية البديلة $H_A: \sigma^2 < \sigma_o^2$ (انظر الشكل الآتي).



الشكل (٦، ١١. ج)

علمًا أنَّ القيمة χ^2 تُحسب من العلاقة الآتية:

$$\chi^2 = \frac{(n-1)s^2}{\sigma_o^2}$$

[11,9]

(٢، ٢، ١١) مثال

زعمت شركة لإنتاج إطارات السيارات أنها على ثقة قدرها 0.99 بأنَّ الإطارات المصنَّعة لديها تتحمَّل في المتوسط مسير 50000 كيلو متر بانحراف معياري قدره 10000 كيلو متر. الآن ومن أجل التَّحَقُّق من زعم هذه الشركة قمنا بسحب عينة من إنتاج هذه الشركة بحجم $n = 36$ إطاراً فوجدنا أنَّ إطارات هذه العينة تتحمَّل في المتوسط مسير 48000 كيلو متر بانحراف معياري قدره 11000 كيلو متر، فإذا افترضنا أنَّ القياسات الناتجة المسافات التي تتحملها هذه الإطارات تتبع التوزيع الطبيعي، فعندئذ:

١- ما هو ردنا على ادعاء هذه الشركة بخصوص متوسط المسافة التي تتحملها الإطارات المصنَّعة لديه إذا أخذنا بقيمة الانحراف المعياري المقدَّم من قبلها؟

٢- ما هو ردنا على ادعاء هذه الشركة بخصوص متوسط المسافة التي تتحملها الإطارات المصنَّعة لديه إذا تجاهلنا قيمة الانحراف المعياري المقدَّم من قبلها، وذلك لأنَّ مُعطيات العينة أثارت لدينا الشك حيال قيمة الانحراف المعياري المقدَّم؟

٣- ما هو ردنا على ادعاء هذه الشركة بخصوص قيمة التباين المقدَّم من قبلها حول المسافة التي تتحملها الإطارات المصنَّعة

لديها؟

الحل: من أجل:

١- من أجل هذا الطلب علينا أن نختبر الفرضية الابتدائية $H_0: \mu = \mu_0 = 50000$ مقابل الفرضية البديلة $H_A: \mu < \mu_0 = 50000$ عند مستوى من الأهمية $\alpha = 0.01$ لأن مستوى الثقة المقدم من قبل الشركة يساوي $1 - \alpha = 0.99$. بالطبع اخترنا هذا النموذج من الفرضيات البديلة، لأننا لاحظنا الفرق الكبير بين القيمة المقدمة من قبل الشركة وتلك التي حصلنا عليها من العينة. الآن وبما أننا سنأخذ بقيمة الانحراف المعياري المقدم من قبل الشركة فإن ذلك يعني أن تباين مجتمع الإطارات معلوم ويساوي $\sigma_0^2 = 10^8$ كيلو متر، ومن ثم تكون منطقة الرفض للفرضية الابتدائية H_0 هي المنطقة المعينة بالمتباينة $z \leq -z_{1-\alpha}$ ، علماً أن قيمة z تحسب بالعلاقة [11,7]، حيث لدينا:

$$z = \frac{\bar{x} - \mu_0}{\sigma_0} \sqrt{n} = \frac{48000 - 50000}{10000} \sqrt{36} = -1.20$$

ومن جهة أخرى نجد $z_{1-\alpha} = z_{0.99} = 2.33$ (اخترنا هذه القيمة لأنه لدينا اختبار وحيد الطرف)، وبملاحظة أن:

$$z = -1.20 > -2.33 = -z_{1-\alpha}$$

فإن ذلك يعني أن قيمة z تقع في منطقة القبول للفرضية الابتدائية، ومن ثم نقبل بادعاء الشركة حول المسافة التي تتحملها إطاراتها، وذلك عند مستوى الأهمية $\alpha = 0.01$.

لاحظ هنا حتى لو أخذنا الفرضية البديلة $H_A: \mu \neq \mu_0 = 48000$ فإننا سنحصل على قبول ادعاء الشركة أيضاً (بخصوص المسافة التي تتحملها الإطارات) عند مستوى الأهمية $\alpha = 0.01$ ، وذلك لأنه لدينا $z_{1-\frac{\alpha}{2}} = z_{0.995} = \frac{2.57 + 2.58}{2} = 2.575$ ، فينتج لدينا من أجل هذه الحالة:

$$z = -1.20 > -2.575 = -z_{1-\frac{\alpha}{2}}$$

٢- في هذه الحالة لدينا تباين مجتمع الإطارات σ^2 مجهولاً، ولذلك للرد على ادعاء الشركة علينا أن نختبر الفرضية الابتدائية $H_0: \mu = \mu_0 = 50000$ مقابل الفرضية البديلة $H_A: \mu < \mu_0 = 50000$ وذلك عند مستوى من الأهمية قدره $\alpha = 0.01$ ، والذي دفعنا إلى أخذ هذه الفرضية البديلة هو ذات السبب الذي ذكرناه في الطلب السابق. الآن، ولتنفيذ هذا الاختبار علينا حساب قيمة t من خلال العلاقة [11,8]، فنجد ما يلي:

$$t = \frac{\bar{x} - \mu_0}{s} \sqrt{n} = \frac{48000 - 50000}{11000} \sqrt{36} = -1.091$$

من جهة أخرى لدينا $t_{1-\alpha}^{[n-1]} = t_{0.99}^{[35]} = 2.438$ ، ومنه ينتج لدينا أن:

$$t = -1.091 > -2.438 = -t_{0.99}^{[35]}$$

ومن ثم نقبل في هذه الحالة بادعاء الشركة أيضاً (حول المسافة التي تتحملها إطاراتها)، وذلك عند مستوى الأهمية $\alpha = 0.01$.

٣- من أجل هذا الطلب علينا اختبار الفرضية الابتدائية $H_0: \sigma^2 = \sigma_0^2 = 10^8$ مقابل الفرضية البديلة: $H_A: \sigma^2 > \sigma_0^2 = 10^8$ عند مستوى من الأهمية قدره $\alpha = 0.01$ ، وقد اخترنا هذا النموذج من الفرضيات البديلة لأننا لاحظنا الفرق الكبير بين القيمة المقدمة من قبل الشركة وتلك التي حصلنا عليها من العينة حيث تولد لدينا شك حيال قيمة التباين المقدمة من قبل الشركة. الآن، ولتنفيذ هذا الاختبار علينا حساب قيمة الإحصاء χ^2 من خلال العلاقة [11,9]، حيث لدينا:

$$\chi = \frac{(n-1)s^2}{\sigma_o^2} = \frac{35 (11000)^2}{10^8} = 42.35$$

وكذلك علينا تعيين قيمة $\chi_{1-\alpha}^{[n-1]}$ من جدول توزيع كاي مربع فنجدها تساوي $\chi_{0.99}^{[35]} = 57.342$ ، ومن ثم يكون لدينا:

$$\chi_{1-\alpha}^{[n-1]} = 57.342 > 42.35 = \chi$$

وهذا يعني أن قيمة χ تقع في منطقة القبول للفرضية الابتدائية H_o ، ومن ثم ليس أمامنا إلا أن نقبل بادعاء الشركة حول التباين المقدم من قبلها، وذلك عند مستوى الأهمية $\alpha = 0.01$.

لاحظ هنا حتى لو أخذنا مقابل الفرضية البديلة $H_A : \sigma^2 \neq \sigma_o^2 = 10^8$ فإننا سنحصل على قبول ادعاء الشركة (بخصوص

التباين) أيضاً، وذلك عند مستوى الأهمية $\alpha = 0.01$ ، وذلك لأنه لدينا $\chi_{1-\frac{\alpha}{2}}^{[n-1]} = \chi_{0.995}^{[35]} = 60.275$ وكذلك $\chi_{\frac{\alpha}{2}}^{[n-1]} = \chi_{0.005}^{[35]} = 17.192$

حيث نلاحظ أن قيمة $\chi = 42.35$ تقع في منطقة القبول للفرضية الابتدائية H_o عند مستوى الأهمية $\alpha = 0.01$.

(١١,٣) الاختبارات الإحصائية من أجل معلمة مجتمع برنولي

Statistical Tests for a Parameter of Bernoulli Population

المبرهنة الآتية (سنقبلها دون برهان أيضاً) تُقدم لنا اختباراً إحصائياً لفرضية تتعلق بمعلمة مجتمع برنولي.

(١١,٣,١) مبرهنة

ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X خاضع لتوزيع برنولي بمعلمة p (احتمال نجاح)، ولنأخذ \mathcal{X}_n عينة من هذا المجتمع، ولتكن لدينا الفرضية الابتدائية $H_o : p = p_o$ ، فعندئذ من أجل مستوى للأهمية قدره α تكون:

١- منطقة الرفض للفرضية الابتدائية H_o مُعَيَّنة بالفترة المحددة بالمتباينة $|\bar{p} - p_o| \geq z_{1-\frac{\alpha}{2}}$ (انظر الشكل السابق (٤, ١١, أ)) إذا كانت الفرضية البديلة من النموذج $H_A : p \neq p_o$ ، علماً أن z تُحسب بالعلاقة الآتية:

$$z = \frac{\bar{p} - p_o}{\sqrt{p_o (1 - p_o)}} \sqrt{n} \quad [11,10]$$

وأما \bar{p} فهي قيمة الإحصاء $\bar{\pi}$ الذي يمثل التكرار النسبي للنجاحات في العينة \mathcal{X}_n .

٢- منطقة الرفض للفرضية الابتدائية H_o مُعَيَّنة بالفترة المحددة بالمتباينة $\bar{p} - z_{1-\alpha} \geq z$ (انظر الشكل السابق (٤, ١١, ب)) إذا كانت الفرضية البديلة من النموذج $H_A : p < p_o$ ، علماً أن z تُحسب بالعلاقة [11,10].

٣- منطقة الرفض للفرضية الابتدائية H_o مُعَيَّنة بالفترة المحددة بالمتباينة $\bar{p} + z_{1-\alpha} \leq z$ (انظر الشكل السابق (٤, ١١, ج)) إذا كانت الفرضية البديلة من النموذج $H_A : p > p_o$ ، علماً أن z تُحسب بالعلاقة [11,10].

(١١,٣,٢) مثال

ادعت إحدى المدارس الشهيرة التي تحوي عدداً كبيراً جداً من الطلاب أنها على ثقة قدرها 98% بأن 15% من طلابها (في مختلف الفصول والسنوات) على الأقل سيحصلون على التقدير A^+ في الاختبار النهائي لمقرر الرياضيات، ومن أجل التحقق من صحة ادعاء هذه المدرسة قمنا بسحب عينة حجمها $n = 81$ طالباً من الذين تقدموا للاختبار النهائي لمقرر الرياضيات، فوجدنا من بينهم 11 طالباً قد حصلوا على التقدير A^+ ، والسؤال: هل تؤيد معطيات هذه العينة صحة ادعاء المدرسة؟

ومن ثم لنبحث عن الإجابة على هذا السؤال إذا كنا قد أعدنا سحب العينة بحيث تشتمل 450 طالباً، وأننا قد وجدنا من بينهم 50 طالباً قد حصلوا على التقدير A^+ .

الحل: نلاحظ هنا أن الكشف عن نتيجة كل طالب تقدّم للاختبار النهائي لمقرّر الرياضيات هي تجربة برنولية، فإما أن يكون قد حقّق النتيجة A^+ أو لم يتمكن من ذلك (نجاح إذا حقّق النتيجة A^+ ، أو فشل إذا لم يحقّق النتيجة A^+)، وهذه النتائج مستقل بعضها عن بعض (تحت الافتراض بأنّ الاختبار كان نزيهاً)، ولذلك حتى نجيب على هذا السؤال المطروح علينا اختبار الفرضية الابتدائية $H_0: p = p_o = 0.15$ مقابل الفرضية البديلة $H_A: p \neq p_o = 0.15$ عند مستوى الأهمية $\alpha = 0.02$ ، وذلك لأنّ مستوى الثقة التي قدّمته المدرسة يساوي $1 - \alpha = 0.98$.

الآن، ومن أجل تنفيذ هذا الاختبار يجب حساب قيمة \bar{p} ومن ثمّ z ، حيث لدينا $\bar{p} = \frac{11}{81} = 0.1358$ ، وأما قيمة z فإنّها تحسب وفقاً للعلاقة [11,10]، فنجدها تساوي:

$$z = \frac{\bar{p} - p_o}{\sqrt{p_o (1 - p_o)}} \sqrt{n} = -0.358$$

وأخيراً علينا تعيين قيمة $z_{1-\frac{\alpha}{2}} = z_{0.99}$ من جدول التوزيع الطبيعي المعياري، فنجدها تساوي $z_{1-\frac{\alpha}{2}} = z_{0.99} \approx 2.33$ ، وهكذا يكون لدينا:

$$|z| = 0.358 < 2.33 \approx z_{0.99}$$

ومن ثمّ قيمة z تقع في منطقة القبول للفرضية الابتدائية H_0 ، ومن ثمّ ليس أمامنا إلاّ القبول بادعاء المدرسة عند مستوى الأهمية $\alpha = 0.02$.

الآن، ومن أجل المعطيات الجديدة للعينة الثانية نجد أن $\bar{p} = \frac{50}{450} = 0.11$ ، وأما قيمة z فتحسب وفقاً للعلاقة [11,10]، فنجدها تساوي:

$$z = \frac{\bar{p} - p_o}{\sqrt{p_o (1 - p_o)}} \sqrt{n} = \frac{0.11 - 0.15}{\sqrt{0.15(1 - 0.15)}} \sqrt{450} = -2.376$$

وهكذا يكون لدينا:

$$z_{0.99} \approx 2.33 < 2.376 = |z|$$

ومن ثمّ قيمة z تقع في منطقة الرفض للفرضية الابتدائية H_0 ، وبناءً على ذلك نرفض ادعاء المدرسة عند مستوى الأهمية $\alpha = 0.02$. نلاحظ أنّه في الطلب السابق لم يكن لدينا من معطيات العينة ما يدفعنا لرفض الفرضية الابتدائية H_0 ، في حين أنّه بزيادة حجم العينة (من ثمّ زيادة كمية المعلومات حول المعلمة p) حصلنا على رفض لهذه الفرضية وهو يعدّ إقراراً بخطئها.

(١١,٤) اختبارات من أجل الفرق بين متوسطي مجتمعين طبيعيين مستقلين

تقدّم لنا المبرهنة الآتية (سنقبلها جميعاً دون برهان) اختبارات لفرضيات متعلّقة بالفرق بين متوسطي مجتمعين طبيعيين.

(١١,٤,١) مبرهنة

ليكن لدينا $[\Omega_1, \mathcal{F}_1, \mathbb{P}_1]$ مجتمعاً موصوفاً من خلال متغيّر عشوائي X خاضع للتوزيع $N(\mu_1, \sigma_1)$ ولنأخذ \mathcal{X}_n عينة من هذا المجتمع. كذلك ليكن $[\Omega_2, \mathcal{F}_2, \mathbb{P}_2]$ مجتمعاً آخر مستقل عن $[\Omega_1, \mathcal{F}_1, \mathbb{P}_1]$ وموصوفاً من خلال متغيّر عشوائي Y خاضع

للتوزيع $N(\mu_2, \sigma_2)$ ، ولناخذ y_m عينة مسحوبة من هذا المجتمع الأخير، فإذا كانت $H_0: \mu_1 - \mu_2 = a_0$ فرضية ابتدائية يُطلب اختبارها عند مستوى من الأهمية α ، علماً أن a_0 ثابت حقيقي، فعندئذ منطقة الرفض لهذه الفرضية تُعَيَّن على النحو الآتي:

١- إذا كان الانحراف المعياري (أو التباين) للمجتمعين معلوماً ولهما القيم $\sigma_1 = \sigma_{1,o}$ و $\sigma_2 = \sigma_{2,o}$ فعندئذ:

أ- تُعطى منطقة الرفض للفرضية الابتدائية H_0 بوساطة المتباينة $|z| \leq z_{1-\frac{\alpha}{2}}$ إذا كانت الفرضية البديلة من النموذج:

$$H_A: \mu_1 - \mu_2 \neq a_0$$

ب- تُعطى منطقة الرفض للفرضية الابتدائية H_0 بوساطة المتباينة $z \geq z_{1-\alpha}$ إذا كانت الفرضية البديلة من النموذج:

$$H_A: \mu_1 - \mu_2 > a_0$$

ج- تُعطى منطقة الرفض للفرضية الابتدائية H_0 بوساطة المتباينة $z \leq -z_{1-\alpha}$ إذا كانت الفرضية البديلة من النموذج:

$$H_A: \mu_1 - \mu_2 < a_0$$

علماً أن z تُحسب بوساطة العلاقة الآتية:

$$z = \frac{(\bar{x} - \bar{y}) - a_0}{\sqrt{m\sigma_{1,o}^2 + n\sigma_{2,o}^2}} \sqrt{n \cdot m} \quad [11,11]$$

٢- إذا كان الانحراف المعياري (أو التباين) للمجتمعين مجهولاً $\sigma_1 = ?$ و $\sigma_2 = ?$ ، ولكن مع الافتراض بتساويهما (أي إن

$\sigma_1 = \sigma_2$)، فعندئذ:

أ- تُعطى منطقة الرفض للفرضية الابتدائية H_0 بوساطة المتباينة $|t| \leq t_{1-\frac{\alpha}{2}}^{[n+m-2]}$ إذا كانت الفرضية البديلة من النموذج:

$$H_A: \mu_1 - \mu_2 \neq a_0$$

ب- تُعطى منطقة الرفض للفرضية الابتدائية H_0 بوساطة المتباينة $t \leq t_{1-\alpha}^{[n+m-2]}$ إذا كانت الفرضية البديلة من النموذج:

$$H_A: \mu_1 - \mu_2 > a_0$$

ج- تُعطى منطقة الرفض للفرضية الابتدائية H_0 بوساطة المتباينة $t \geq t_{1-\alpha}^{[n+m-2]}$ إذا كانت الفرضية البديلة من النموذج:

$$H_A: \mu_1 - \mu_2 < a_0$$

علماً أن قيمة t تُحسب بوساطة العلاقة الآتية:

$$t = \frac{[(\bar{x} - \bar{y}) - a_0] \sqrt{n \cdot m \cdot (n+m-2)}}{\sqrt{(m+n)[(n-1)S_X^2 + (m-1)S_Y^2]}} \quad [11,12]$$

(١١، ٤، ٢) ملاحظات

١- في الحالة الخاصة عندما يكون لدينا $a_0 = 0$ فإن الاختبارات السابقة في المبرهنة (١١-٤-١) تؤول إلى اختبارات متعلقة بتساوي متوسطي مجتمعين طبيعيين مستقلين.

٢- في حال كان σ_1 و σ_2 مجهولين ولم تُقدَّم أية معلومات حول تساويهما، فعندئذ يجب التحقق أولاً إن كان $\sigma_1^2 = \sigma_2^2$ باحتمال قدره $1-\alpha$ أم لا، وذلك من خلال تعيين $100(1-\alpha)\%$ فترة ثقة للنسبة σ_1^2 / σ_2^2 والمُعطاة بالفترة [10-34-b]، فإذا كان العدد (1) ينتمي إلى هذه الفترة، فعندئذ يكون لدينا $\sigma_1^2 = \sigma_2^2$ باحتمال قدره $1-\alpha$ ، ومن ثم نتابع بتطبيق الاختبار الخاص بالحالة $\sigma_1^2 = \sigma_2^2$. أما إذا كان العدد (1) لا ينتمي إلى تلك الفترة، فعندئذ نتوقف عن تنفيذ الاختبار لأنه لا يُحقق الفرضيات المطلوبة، والاختبار الذي يعالج مثل هذه الحالة لن نتطرق إليه.

(١١,٥) اختبارات من أجل نسبة التباين لمجتمعين طبيعيين مستقلين

تقدم لنا المبرهنة الآتية اختباراً لفرضية تتعلق بنسبة التباين لمجتمعين طبيعيين مستقلين.


(١١,٥,١) مبرهنة

ليكن لدينا $[\Omega_1, \mathcal{S}_1, \mathcal{P}_1]$ مجتمعاً موصوفاً من خلال متغير عشوائي X خاضع للتوزيع $N(\mu_1, \sigma_1)$ ولنأخذ عينة من \mathcal{X}_n عينة من هذا المجتمع. كذلك ليكن $[\Omega_2, \mathcal{S}_2, \mathcal{P}_2]$ مجتمعاً آخر مستقل عن المجتمع $[\Omega_1, \mathcal{S}_1, \mathcal{P}_1]$ وموصوفاً من خلال متغير عشوائي Y خاضع للتوزيع $N(\mu_2, \sigma_2)$ ، ولنأخذ عينة مسحوبة من المجتمع الثاني. الآن بفرض أن $\frac{\sigma_1^2}{\sigma_2^2} = u_0$ فرضية ابتدائية يطلب اختبارها عند مستوى من الأهمية α ، علماً أن u_0 ثابت حقيقي، فعندئذ منطقة الرفض لهذه الفرضية تُعين على النحو الآتي:


١- تُعطي منطقة الرفض للفرضية الابتدائية H_0 بوساطة المتباينتين الآتيتين:

$$f \leq f_{\frac{\alpha}{2}}^{[m-1; n-1]} = \left(f_{1-\frac{\alpha}{2}}^{[m-1; n-1]} \right)^{-1} \quad \& \quad f \geq f_{1-\frac{\alpha}{2}}^{[m-1; n-1]}$$


إذا كانت الفرضية البديلة من النموذج $H_A: \frac{\sigma_1^2}{\sigma_2^2} \neq u_0$ (للتوضيح انظر الشكل الآتي (١١,٧)).



٢- تُعطي منطقة الرفض للفرضية H_0 بوساطة المتباينة $f_{1-\alpha}^{[m-1; n-1]} \leq f$ إذا كانت الفرضية البديلة $H_A: \frac{\sigma_1^2}{\sigma_2^2} > u_0$ (للتوضيح انظر الشكل الآتي (١١,٧) ب)).



٣- تُعطي منطقة الرفض للفرضية H_0 بوساطة المتباينة $f_{\alpha}^{[m-1; n-1]} \geq f$ إذا كانت الفرضية البديلة $H_0: \frac{\sigma_1^2}{\sigma_2^2} < u_0$ (للتوضيح انظر الشكل الآتي (١١، ٧)).



الشكل (١١، ٧) ج

علماً أن $f_{\alpha}^{[m-1; n-1]} = (f_{1-\alpha}^{[m-1; n-1]})^{-1}$ وأما قيمة f فإنها تُحسب بوساطة العلاقة الآتية:

$$f = \frac{S_2^2}{S_1^2} \cdot u_0 \quad [11,13]$$

(١١، ٥، ٢) ملاحظة

في الحالة الخاصة عندما يكون $u_0 = 1$ فإن الاختبارات السابقة في المبرهنة (١١، ٥، ١) تؤول إلى اختبارات متعلقة بتساوي التباين لمجتمعين طبيعيين مستقلين.

(١١، ٥، ٣) مثال

تقدمت شركتان A_1 و A_2 لإنتاج الدواء بعروضهما إلى وزارة الصحة لتزويدها بنوع من أدوية الالتهابات (وليكن على سبيل المثال كبسولات أموكسيل عيار 500mg) حيث ادعت الشركة A_1 أنها على ثقة قدرها 99% بأن متوسط وزن المادة الفعالة في منتجها المقدم 500 mg بانحراف معياري قدره 25mg، في حين ادعت الشركة الأخرى A_2 أنها على ثقة قدرها 99% أيضاً بأن متوسط وزن المادة الفعالة في منتجها المقدم 500mg بانحراف معياري قدره 25mg أيضاً. الآن لكي تحدد الوزارة أي الشركتين ستختار قامت بسحب عينة X_{36} من منتج الشركة A_1 وأخضعتها للتحليل فوجدت أن متوسط وزن المادة الفعالة في هذه العينة 480mg بانحراف معياري قدره 20mg، وكذلك قامت بسحب عينة أخرى Y_{49} من منتج الشركة A_2 وأخضعتها للتحليل فوجدت أن متوسط وزن المادة الفعالة في هذه العينة 505mg بانحراف معياري قدره 15mg. الآن، وتحت الفرض أن أوزان المادة الفعالة في الدواء له توزيع طبيعي، لنقم بما يلي:

١- تحديد أي الشركتين يجب اختيارها لتوريد الدواء إذا كانت الوزارة:

أ- ستأخذ بقيم الانحراف المعياري المقدم من قبل الشركتين؟

ب- ستتجاهل قيم الانحراف المعياري المقدم من قبل الشركتين؟

٢- لنختبر الفرضية القائلة بتساوي التباين لدى مجتمعي أدوية الشركتين.

الحل: سنفترض أن X و Y هو المتغير العشوائي الواسف لمجتمع كبسولات الشركة A_1 و A_2 على الترتيب، فيكون لدينا $X \sim N(\mu_1, \sigma_1)$ و $Y \sim N(\mu_2, \sigma_2)$ ، ومن ثم لكي نحدد أي الشركتين يجب اختيارها لتوريد الدواء إلى الوزارة علينا اختبار

الفرضية الابتدائية $H_0: \mu_1 = \mu_2$ عند مستوى الأهمية $\alpha = 0.01$ ، وذلك لأن مستوى الثقة المقدم $1 - \alpha = 0.99$ ، ومن أجل استكمال دراسة هذا الاختبار وفقاً للحالات التي اتخذناها نجد ما يلي:

من أجل الطلب الأول: وبخصوص الفقرة:

أ - نلاحظ من معطيات العينات أنه من المرجح أن يكون $\mu_1 < \mu_2$ ولذلك يفضل في مثل هذه الحالة اختيار الفرضية البديلة $H_A: \mu_1 < \mu_2$ مع الأخذ بالحسبان أن قيم الانحراف المعياري (ومن ثم التباين) للمجتمعين معلومة حيث لدينا $\sigma_1 = \sigma_{1,o} = 25$ و $\sigma_2 = \sigma_{2,o} = 25$. عندئذ تُعطى منطقة الرفض للفرضية الابتدائية H_0 بوساطة المتباينة $-z_{1-\alpha} \geq z$ ، علماً أن z تُحسب بوساطة العلاقة [11,11] حيث لدينا:

$$z = \frac{(\bar{x} - \bar{y}) - a_0}{\sqrt{m \sigma_{1,o}^2 + n \sigma_{2,o}^2}} \sqrt{n \cdot m} = \frac{(480 - 505) - 0}{\sqrt{49 \times 25 + 36 \times 25}} \sqrt{49 \times 36} = -1$$

وبما أن $z_{1-\alpha} = z_{0.99} \approx 2.33$ فإنه ينتج لدينا أن:

$$-z_{1-\alpha} = -2.33 < -1 = z$$

ومن ثم نجد أن قيمة z تقع في منطقة القبول للفرضية H_0 ، ومن ثم يمكن اختيار أي من الشركتين لتوريد الدواء عند مستوى الأهمية $\alpha = 0.01$ ، وأن ما ظهر من فوارق في نتائج تحليل العينات هي فوارق ظاهرية لا أهمية لها عند هذا مستوى الأهمية المعطى.

ب - سنأخذ الفرضية البديلة $H_A: \mu_1 < \mu_2$ أيضاً، ولكن من أجل هذه الحالة قيم التباين للمجتمعين مجهولة $\sigma_1^2 = ?$ و $\sigma_2^2 = ?$. عندئذ تُعطى منطقة الرفض للفرضية H_0 بوساطة المتباينة $t \leq t_{1-\alpha}^{[n+m-2]}$ ، علماً أن t تُحسب بوساطة العلاقة [11,12]، ولكن قبل استكمال دراسة هذا الاختبار علينا التحقق أولاً من تساوي التباين للمجتمعين وذلك من خلال تعيين 99% فترة ثقة للنسبة σ_1^2 / σ_2^2 ، علماً أن هذه الفترة تُعطى بالفترة [10,34-b] حيث لدينا من جدول توزيع فيشر ما يلي:

$$f_{1-\frac{\alpha}{2}}^{[m-1; n-1]} = f_{0.995}^{[48; 35]} \approx \frac{2.63 + 2.42}{2} = 2.525$$

وبالتعويض في الفترة [10,34-b] كل بما يساويه يكون لدينا 99% فترة ثقة للنسبة $\frac{\sigma_1^2}{\sigma_2^2}$ هي:

$$\left(\frac{S_x^2}{S_y^2} \cdot f_{1-\frac{\alpha}{2}}^{[m-1; n-1]} \right)^{-1}, \frac{S_x^2}{S_y^2} \cdot f_{1-\frac{\alpha}{2}}^{[m-1; n-1]} = \left(\frac{400}{225} (2.525)^{-1}, \frac{400}{225} (2.525) \right) = (0.704, 4.489)$$

وهكذا نجد أن هذه الفترة تحوي العدد (1)، ومن ثم لدينا $\sigma_1^2 = \sigma_2^2$ باحتمال قدره 0.99، ومن ثم يمكننا متابعة دراسة الاختبار حيث لدينا من جدول توزيع ستودنت $t_{1-\alpha}^{[n+m-2]} = t_{0.99}^{[83]} = 2.372$ ، وبالتعويض كل بما يساويه في العلاقة [11,12] ينتج لدينا:

$$t = \frac{[(480 - 505) - 0] \sqrt{(36)(49)(36 + 49 - 2)}}{\sqrt{(49 + 36)[35 \times 400 + 48 \times 225]}} = -0.08$$

وهكذا نلاحظ أن:

$$t_{1-\alpha}^{[n+m-2]} = -2.372 < -0.08 = t$$

ومن ثم قيمة t تقع في منطقة القبول للفرضية الابتدائية H_0 ، وبالتالي يمكن اختيار أي من الشركتين لتوريد الدواء عند مستوى الأهمية $\alpha = 0.01$ أيضاً، وأن ما ظهر من فوارق في نتائج تحليل العينات في هذه الحالة هي فوارق ظاهرية أيضاً ولا أهمية لها عند هذا المستوى من الأهمية.

من أجل الطلب الثاني:

من أجل اختبار الفرضية القائلة بتساوي التباين لدى مجتمعي أدوية الشركتين نلاحظ أننا سنتوقع القبول لهذه الفرضية لأننا استنتجنا في الطلب السابق أن $\sigma_1^2 = \sigma_2^2$ باحتمال قدره 0.99، ولكن لتنفيذ الاختبار سنأخذ الفرضية الابتدائية $H_0: \sigma_1^2 = \sigma_2^2$ مقابل الفرضية البديلة $H_A: \sigma_1^2 \neq \sigma_2^2$ عند مستوى من الأهمية $\alpha = 0.01$. حيث نعلم أن منطقة الرفض للفرضية H_0 تُعطى من خلال المتبايتين الآتيتين:

$$f \geq f_{1-\frac{\alpha}{2}}^{[m-1; n-1]} = f_{0.995}^{[48; 351]} \approx 2.525 \quad \& \quad f \leq \left(f_{1-\frac{\alpha}{2}}^{[m-1; n-1]} \right)^{-1} = \left(f_{0.995}^{[48; 351]} \right)^{-1} \approx \frac{1}{2.525} = 0.396$$

علماً أن f تُحسب بوساطة العلاقة [11,13] حيث لدينا:

$$f = \frac{S_Y^2}{S_X^2} \cdot b_o = \frac{225}{400} \times 1 = 0.5625$$

فنلاحظ أن قيمة f تقع في منطقة القبول للفرضية الابتدائية H_0 (وهذا ما توقعناه مسبقاً)، ومن ثم نقبل بفرضية تساوي تباين أوزان المادة الفعالة في كبسولات أدوية الشركتين وذلك عند مستوى الأهمية $\alpha = 0.01$.

(١١, ٦) اختبارات من أجل الفرق بين معلمتي مجتمعين برنوليين مستقلين

تقدم لنا المبرهنة الآتية (نقبلها دون برهان) اختباراً لفرضية إحصائية متعلقة بالفرق بين معلمتي مجتمعين برنوليين مستقلين.

(١١, ٦, ١) مبرهنة

ليكن $[\Omega_1, \mathcal{S}_1, \mathcal{P}_1]$ مجتمعاً موصوفاً من خلال متغير عشوائي X خاضع للتوزيع $B(p_1)$ ، ولنأخذ عينة من هذا المجتمع. كذلك لنأخذ $[\Omega_2, \mathcal{S}_2, \mathcal{P}_2]$ مجتمعاً آخر مستقل عن $[\Omega_1, \mathcal{S}_1, \mathcal{P}_1]$ وموصوفاً من خلال متغير عشوائي Y خاضع للتوزيع $B(p_2)$ ، ولنأخذ عينة مسحوبة من هذا المجتمع الثاني، ولتكن $H_0: p_1 - p_2 = b_o$ فرضية ابتدائية يطلب اختبارها عند مستوى من الأهمية α ، علماً أن b_o ثابت حقيقي. إن منطقة الرفض للفرضية الابتدائية H_0 تُعين على النحو الآتي:

١- تُعطى منطقة الرفض للفرضية الابتدائية H_0 بوساطة المتباينة $|z| \leq z_{1-\frac{\alpha}{2}}$ إذا كانت الفرضية البديلة من النموذج:

$$H_A: p_1 - p_2 \neq b_o.$$

٢- تُعطى منطقة الرفض للفرضية الابتدائية H_0 بوساطة المتباينة $z \leq z_{1-\alpha}$ إذا كانت الفرضية البديلة من النموذج:

$$H_A: p_1 - p_2 > b_o$$

٣- تُعطى منطقة الرفض للفرضية الابتدائية H_0 بوساطة المتباينة $-z \leq z_{1-\alpha}$ إذا كانت الفرضية البديلة من النموذج:

$$H_A: p_1 - p_2 < b_o$$

علماً أن z تُحسب بوساطة العلاقة الآتية:

$$Z = \frac{(\bar{p}_1 - \bar{p}_2) - b_o}{\sqrt{\bar{p}(1-\bar{p})\left(\frac{1}{n} + \frac{1}{m}\right)}}; \bar{p} = \frac{k+\ell}{n+m} \quad [11,14]$$

والعددين k و ℓ هما عدد النجاحات في العينة \mathcal{X}_n و \mathcal{Y}_m على الترتيب.

(١١, ٦, ٢) ملاحظة

يلاحظ أنه في الحالة الخاصة عندما يكون $b_o = 0$ فإن الاختبارات السابقة تؤول إلى اختبارات تتعلق بتساوي معلمتي مجتمعين برنوليين مستقلين.

(١١, ٦, ٣) مثال

يقوم مدرّسان A و B بتصحيح دفاتر امتحانية لمقرّر الإحصاء وبشكل مستقل كل منهما عن الآخر. قمنا بأخذ عينة من الدفاتر المصحّحة من قبل المدرس A و B بحجم $n = 225$ و $m = 200$ دفترًا امتحانيًا على الترتيب، ولدى مراجعة التصحيح لهذه الدفاتر وجد أن لدى A و B دفاتر تحوي أخطاءً في التصحيح عددها 20 و 17 دفترًا على الترتيب. والسؤال هنا:

هل تدلّ هذه النتائج أن للمدرّسين الكفاءة نفسها في دقّة التصحيح عند مستوى من الأهمية قدره $\alpha = 0.01$ ؟

الحل: نلاحظ هنا أن عمليات التصحيح للدفاتر الامتحانية هي تجارب برنولية (إما أن يكون الدفتر قد صُحّح بدون أخطاء، أو أن المدرس أخطأ في تصحيحه) مستقلة (لأن كل مدرّس يصحّح بشكل مستقل عن الآخر)، فإذا كان $\Omega_1, \mathcal{F}_1, \mathcal{P}_1 = \{P_{p_1}; 0 < p_1 < 1\}$ هو المجتمع الممثل للدفاتر المصحّحة من قبل المدرس A، و $\Omega_2, \mathcal{F}_2, \mathcal{P}_2 = \{P_{p_2}; 0 < p_2 < 1\}$ هو المجتمع الممثل للدفاتر المصحّحة من قبل المدرس B، فعندئذ للإجابة على السؤال المطروح علينا اختبار الفرضية الابتدائية $H_o: p_1 = p_2$ مقابل الفرضية البديلة $H_A: p_1 \neq p_2$ عند مستوى الأهمية $\alpha = 0.01$.

الآن، من معطيات المسألة لدينا $\bar{p}_1 = \frac{20}{225} = 0.089$ وكذلك $\bar{p}_2 = \frac{17}{200} = 0.085$ ، ومن أجل $\alpha = 0.01$ لدينا:

$$z_{1-\frac{\alpha}{2}} = z_{0.995} \approx \frac{2.57 + 2.58}{2} = 2.575$$

وأما قيمة z فإنها تحسب من العلاقة [11,14] حيث لدينا:

$$z = \frac{(\bar{p}_1 - \bar{p}_2) - b_o}{\sqrt{\bar{p}(1-\bar{p})\left(\frac{1}{n} + \frac{1}{m}\right)}}$$

والتعويض عن كل رمز بما يساويه وتنفيذ العمليات الحسابية عليها ينتج لدينا الآتي:

$$z = \frac{(0.089 - 0.085) - 0}{\sqrt{0.087(1-0.087)\left(\frac{1}{225} + \frac{1}{200}\right)}} = 0.5182$$

ومن ثم نجد أن قيمة z تقع في منطقة القبول للفرضية الابتدائية H_o ، وبالتالي نقبل أن للمدرّسين الدقّة نفسها في التصحيح وذلك عند مستوى الأهمية $\alpha = 0.01$.

(١١, ٧) اختبارات إحصائية من أجل فرضيات غير معلمية

Statistical Tests for Non-Parametric Hypothesis

قدّ منا فيما سبق بعض الاختبارات المعلمية الأكثر شيوعاً واستخداماً، إلا أنه توجد فرضيات إحصائية كثيرة تقع خارج إطار تلك الدراسة لعدم تعلّق الفرضية بمعالم المجتمع، كأن يكون الهدف من الاختبار الإحصائي هو التحقق من أن التوزيع الاحتمالي للمجتمع يوافق توزيعاً احتمالياً معلوماً (اختبار فرضيات توفيق التوزيعات الاحتمالية). كذلك من الممكن أن يكون الهدف من الاختبار

الإحصائي التحقق من استقلال توزيعين أو ظاهرتين لمجتمعين (اختبار فرضيات الاستقلال)، وقد يكون الهدف من ذلك التحقق من التطابق في التوزيع لعدد منته من المجتمعات (اختبار فرضيات التجانس). وهناك الكثير من الاختبارات الإحصائية التي تتناول قطاعات أخرى في نظرية اختبار الفرضيات الإحصائية.

سنقوم فيما يلي بتقديم بعض الاختبارات غير المعلمية مبتدئين بما يعرف باسم اختبارات جودة توفيق التوزيعات (التوزيعات الاحتمالية) التي تنطوي تحت الاختبارات غير المعلمية.

(١, ٧, ١١) اختبارات جودة توفيق توزيع احتمالي Goodness of Distribution Fit Tests

لقد رأينا أنه من أجل مجتمع $[\Omega, \mathcal{S}, \mathcal{P}]$ موصوف من خلال متغير عشوائي X دالة كثافته الاحتمالية $f_X(\cdot; \theta)$ وبدالة توزيع احتمالية F_X مجهولتين يمكننا أن نشكل صورة تقريبية عن F_X من خلال سحب عينة \mathcal{X}_n من هذا المجتمع، ومن ثم تعيين دالة التوزيع العملية للعينة $F_{n,o}$ التي تتقارب من F_X بشكل منتظم (بحسب مبرهنة غليفينكو)، كما أن المضلع التكراري لهذه العينة يعطينا عرضاً تقريبياً لدالة الكثافة الاحتمالية $f_X(\cdot; \theta)$. إن هذه التقريبات تدعونا إلى وضع فرضية حول نوع التوزيع الاحتمالي الذي يخضع له المجتمع، ومن ثم اختبار هذه الفرضية عند مستوى معين من الأهمية α .

سنقدمها فيما يلي أحد اختبارات جودة التوفيق، ويدعى اختبار كاي مربع لجودة التوفيق، وكان قد قدمه لأول مرة الإحصائي بيرسون.

(١, ٧, ١١) اختبار كاي مربع لجودة التوفيق Chi-Squared Test for Goodness of Fit

إن اختبار كاي مربع لجودة توفيق توزيع احتمالي ينطلق من الآتي:

بفرض أنه لدينا $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمع موصوف من خلال متغير عشوائي X دالة توزيعه الاحتمالية F_X مجهولة، فعندئذ لا اختبار إن كان توزيع هذا المجتمع يتوافق مع توزيع احتمالي F_o (نعتقد أنه مناسب لهذا المجتمع) عند مستوى من الأهمية α نقوم بتنفيذ الخطوات الست الآتية:

- ١- نسحب عينة \mathcal{X}_n من هذا المجتمع.
- ٢- نضع الفرضية الابتدائية $H_o: F_X \equiv F_o$.
- ٣- تكون الفرضية البديلة في هذه الدراسة هي $H_A: F_X \neq F_o$.
- ٤- نقوم بتجزئة العينة \mathcal{X}_n في m فئة منفصلة متنى متنى.
- ٥- نحسب قيمة الإحصاء الآتي:

$$U = \sum_{k=1}^m \frac{(O_k - E_k)^2}{E_k} \quad [11,15]$$

علماً أن:

O_k هو التكرار المشاهد للظاهرة لدى الفئة k الذي يمثل التكرار المطلق للفئة k ، حيث نلاحظ أن O_k متغير عشوائي وقيمته تُعبر عن عدد المرات التي يأخذ فيها X قيمة في الفئة k .

E_k هو التكرار المتوقع للفئة k وبحسب العلاقة $E_k = n \cdot p_k$ ، علماً أن p_k هو احتمال أن يأخذ المتغير العشوائي قيمة في الفئة k وذلك باستخدام التوزيع الاحتمالي F_o ، وهكذا نلاحظ أن p_k هو التكرار النسبي المتوقع للفئة ذات الرقم k .

٦- تعيين عدد صحيح r يمثل عدد المعالم المقدرة للتوزيع F_o .

عندئذ بفرض أن u هي قيمة الإحصاء U فإننا:

أ - نقبل الفرضية الابتدائية H_0 عند مستوى الأهمية α إذا كان $\chi_{1-\alpha}^{[k-r-1]} > u$.

ب - نرفض الفرضية الابتدائية H_0 عند مستوى الأهمية α إذا كان $\chi_{1-\alpha}^{[k-r-1]} \leq u$.

(١, ١, ٧, ١١) ملاحظات

١ - إن التكرار المتوقع E_k يجب ألا يكون صغيراً، إذ يُفضل أن يكون $5 \leq E_k$ من أجل أي $k \in \mathbb{N}_m$ ، وفي حال عدم تحقق المتباينة السابقة نقوم بدمج بعض الفئات بعضها مع البعض الآخر بحيث تتحقق المتباينة السابقة.

٢ - إذا كان X متغيراً عشوائياً متقطعاً، فعندئذ من الأفضل أن نقوم باختبار الفرضية الابتدائية:

$$H_0 : P_\theta(X = k) = P_{\theta_0}(X = k)$$

علماً أن θ_0 هي معلّمة التوزيع التي قيد الاختبار، ويتم تقديرها من العينة إن كانت مجهولة.

٣ - من إيجابيات هذا الاختبار أنه يمكن تطبيقه على أي توزيع وحيد البعد (بمتغير واحد) حيث يمكن حساب دالة توزيعه التراكمية.

٤ - لهذا الاختبار سلبياتان هما:

أ - إن قيمة الإحصاء U للاختبار تعتمد على جدولة البيانات، وهذه نقطة سلبية لكونها تتطلب الكثير من الجهد.

ب - يتطلب أن يكون حجم العينة كبيراً بقدر كافٍ لكي يكون التقريب مقبولاً (أو جيداً).

(١, ١, ٧, ١١, ٢) مثال (تجربة جايجر ومارسدين Geiger-Marsden experiment)

لقد قام (بين عامي ١٩٠٨-١٩١٣) كل من الفيزيائيين الألمانين جايجر Johannes Wilhelm Geiger (1882-1945) ومارسدين Sir Ernest Marsden (1889-1970) وتحت إدارة الفيزيائي النيوزيلاندي ريديفورد Ernest Rutherford (1871-1937) بتجربة حول عدد جسيمات ألفا الصادرة عن المادة المشعة (Polonium) خلال 2608 فترات زمنية قصيرة طول كل منها 7.5 ثانية (انظر [24])، فوجدا النتائج الآتية على افتراض أن O_k هو المتغير العشوائي الذي يرصد عدد الفترات الزمنية التي حصل فيها على k جسيم.

الجدول (١١, ٢)

k	0	1	2	3	4	5	6	7	8	9	10 or more
O_k	57	203	383	525	532	408	273	139	45	27	16

الآن ليكن X متغيراً عشوائياً راصداً لعدد جسيمات ألفا الصادرة عن هذه المادة المشعة خلال فترة زمنية قدرها 7.5 ثانية، ولنقم باختبار الفرضية القائلة إن للمتغير العشوائي X توزيعاً بواسونياً، وذلك عند مستوى من الأهمية قدره $\alpha = 0.05$.

الحل: المطلوب اختبار الفرضية الابتدائية:

$$H_0 : P_\lambda(X = k) = P_{\lambda_0}(X = k) = \frac{\lambda_0^k}{k!} e^{-\lambda_0} ; k \in \mathbb{N}^0$$

عند مستوى من الأهمية $\alpha = 0.05$ مقابل الفرضية البديلة:

$$H_A : P_\lambda(X = k) \neq P_{\lambda_0}(X = k) = \frac{\lambda_0^k}{k!} e^{-\lambda_0} ; k \in \mathbb{N}^0$$

لدراسة هذا الاختبار علينا حساب قيمة المعلّمة λ_0 من العينة \mathcal{X}_n حيث نعلم من المثال ٣ / في (١٠-١-٥) أن \bar{X} هو مُقدّر الأرجحية العظمى لمعلّمة المجتمع البواسوني λ (ويبرهن بسهولة أنه غير منحاز أيضاً)، ومن ثم نجد أن:

$$\bar{X} = \frac{\sum_{k=0}^{10} k O_k}{\sum_{k=0}^{10} O_k} = \frac{10086}{2608} = 3.867 = \lambda_o$$

ومن ثم تكون قيمة p_0 المقابلة لـ $k = 0$ هي:

$$p_0 = P_{\lambda_o}(X = 0) = \frac{(3.867)^0}{0!} e^{-3.867} = 0.021$$

وكذلك تكون قيمة p_1 المقابلة لـ $k = 1$ هي:

$$p_1 = P_{\lambda_o}(X = 1) = \frac{(3.867)^1}{1!} e^{-3.867} = 0.081$$

وبالمثل نجد بقية القيم لـ p_k المقابلة لـ k والمقدمة في الجدول الآتي: p_k

الجدول (١١, ٣)

k	0	1	2	3	4	5	6	7	8	9	10 or more
p_k	0.021	0.081	0.156	0.201	0.195	0.151	0.097	0.054	0.026	0.011	0.007

ومن ثم يكون لـ u (قيمة الإحصاء U المعطى بالعلاقة [11,15]) القيمة الآتية:

$$u = \sum_{k=0}^{10} \frac{(O_k - n \cdot p_k)^2}{n \cdot p_k} = 13.049$$

ومن جهة أخرى نعلم أن لتوزيع بواسون معلمة واحدة تم تقديره سابقاً، ولذلك يكون لدينا $r = 1$ ، وكذلك لدينا $m = 11$ (لأنه لدينا إحدى عشرة فئة منفصلة)، وأخيراً من جدول توزيع كاي مربع نجد $\chi_{1-\alpha}^{[9]} = \chi_{0.95}^{[9]} = 16.9$ ، ومن ثم نلاحظ أن:

$$\chi_{0.95}^{[9]} = 16.9 > 13.049 = u$$

وهذا يعني أنه علينا القبول بالفرضية الابتدائية H_0 القائلة إن توزيع عدد الجسيمات الصادرة عن مادة البولونيوم Polonium خلال فترات زمنية طولها 7.5 من الثواني هو التوزيع البواسوني بمعلمة $\lambda_o = 3.867$ ، وذلك عند مستوى الأهمية $\alpha = 0.05$.

(١١, ٧, ١, ٢) اختبار كلموغوراف – سميرنوف لجودة التوفيق Kolmogorov-Smirnov Test for Goodness of Fit

لقد قدم كل من كلموغوراف والرياضياتي الروسي سميرنوف Nikolai Vasilyevich Smirnov (1900-1966) اختباراً لجودة توفيق توزيع احتمالي (وذلك في عام 1939) مستفيدين من انحرافات قيم دالة التوزيع العملية عن دالة التوزيع النظرية المفترض صحتها. حيث يبين هذا الاختبار إن كان توزيع احتمالي F_o ملائماً لتوزيع هذا المجتمع أم لا، وذلك عند مستوى من الأهمية قدره α .


ولشرح هذا الاختبار سنفترض أن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمع موصوف من خلال متغير عشوائي X دالة توزيعه الاحتمالية F_X مجهولة ولكنها مستمرة، وأن \mathcal{X}_n عينة من هذا المجتمع، فعندئذ يقوم اختبار كلموغوراف – سميرنوف على تنفيذ البنود الآتية:

١- وضع الفرضية الابتدائية $H_0: F_X \equiv F_o$ ، وفي حال رفض H_0 عند مستوى من الأهمية α علينا القبول بفرضية بديلة من الشكل $H_A: F_X \neq F_o$.

٢- من أجل حجم العينة n يُعرف إحصاء KS_n تحسب قيمتها ks_n من خلال العلاقة الآتية:

$$ks_n := \sup_{x \in \mathbb{R}} |F_{n,\omega}(x) - F_o(x)| \quad [11,16-a]$$

علماً أنَّ $F_{n,\omega}$ هي دالة التوزيع العملية للعينة \mathcal{X}_n وتحسب من العلاقة [9-8-a] أو [9-8-b].



الشكل (١١,٨)

٣- تُعَيَّن قيمة عددية سنرمز لها بـ $K_{1-\alpha}^{[n]}$ من جدول كلموغوراف-سميرنوف في آخر هذا الكتاب، وتدعى القيمة الحرجة لاختبار كلموغوراف-سميرنوف.

٤- يُقارن بين القيمتين ks_n و $K_{1-\alpha}^{[n]}$ ، فإذا كان:

أ- لدينا $K_{1-\alpha}^{[n]} < ks_n$ فإننا نرفض الفرضية الابتدائية H_o ونقبل بالفرضية البديلة H_A عند مستوى الأهمية α .

ب- لدينا $K_{1-\alpha}^{[n]} \geq ks_n$ فإننا نقبل الفرضية الابتدائية H_o عند مستوى الأهمية α .

(١١,٧,١,٢,١) ملاحظات

١- بعض المراجع تستخدم العلاقة الآتية لحساب ks_n :

$$ks_n := \sqrt{n} \sup_{x \in \mathbb{R}} |F_{n,\omega}(x) - F_o(x)| \quad [11,16-b]$$

٢- توجد في بعض المراجع جداول للقيم الحرجة تختلف عن التي سنقدمها في نهاية هذا الكتاب، وتلك الجداول خاصة باستخدام اختبار كلموغوراف-سميرنوف عندما تكون دالة التوزيع النظرية هي دالة التوزيع الطبيعي فقط.

٣- لا يستخدم هذا الاختبار إلا إذا كانت دالة التوزيع النظرية مستمرة فقط.

٤- إن هذا الاختبار يعد أكثر حساسية (بالغ الدقة) من أجل القيم القريبة من المتوسط من تلك القيم الأبعد التي تقع عند الأطراف (عند الذيلين)، وهذا يعني أنه يعطي وزناً أكبر للبيانات القريبة من المركز.

(١١,٧,١,٢,٢) مثال

لدى دراسة تعيين التوزيع الزمني لانتهاء عمل دائرة إلكترونية لدى تعرضها لجهد كهربائي أعلى من الجهد المسموح به أخضعت عينة بحجم 10 دارات من المنتج للدراسة، فوجدت المعطيات الآتية مُقدَّرةً بالثانية:

0.5 1 3 3.6 0.3 4 0.1 0.2 5 1.2

ولنختبر الفرضية القائلة إنَّ التوزيع الزمني لانتهاء الدارات هو التوزيع الأسّي، وذلك عند مستوى من الأهمية قدره $\alpha = 0.10$.

الحل: من أجل ذلك علينا اختبار الفرضية الابتدائية $H_o : F_X(x) \equiv F_o(x) = \lambda_o e^{-\lambda_o x} I_{(0, \infty)}(x)$ مقابل الفرضية

البديلة $H_A : F_X(x) \neq F_o(x)$ عند مستوى الأهمية $\alpha = 0.10$.

الآن، ولتنفيذ هذا الاختبار علينا تعيين قيمة المعلمة λ_o ، حيث يمكن إثبات أن مُقدّر معلّمة المجتمع الأسّي هو $\hat{\lambda} = \frac{1}{\bar{X}}$ (استخدم طريقة العزوم أو الأرجحية العظمى للحصول على هذه النتيجة)، ومنه نجد أن قيمة الإحصاءة $\hat{\lambda}$ تساوي $\hat{\lambda} = 0.529$ ، ومن ثمّ سنأخذ $\lambda_o = 0.529$ من أجل $F_o(x)$.


بعد ذلك لنقم لترتيب القيم التي حصلنا عليها من العينة تصاعدياً، ومن ثمّ حساب القيم $F_n(x)$ و $F_o(x)$ فتكون النتائج كما في الجدول (١١، ٤) الآتي، حيث نجد $ks_n = 0.1955$.

الخطوة التالية هي إيجاد قيمة $K_{1-\alpha}^{[n]}$ من جدول توزيع كلموغوراف، حيث نجد $K_{1-\alpha}^{[n]} = K_{0.90}^{[10]} = 0.369$ ، ومنه ينتج لدينا:
 $K_{1-\alpha}^{[n]} = 0.369 > 0.1955 = ks_n$
ومن ثمّ ليس أمامنا إلاّ القبول بالفرضية الابتدائية H_o عند مستوى الأهمية $\alpha = 0.10$.


الجدول (١١، ٤)

الفئة	x_i	$F_{n,\omega}(x_i)$	$F_o(x_i)$	$ F_{n,\omega}(x_i) - F_o(x_i) $
1	0.1	0	0.052	0.0515
2	0.2	0.1	0.100	0.0004
3	0.3	0.2	0.147	0.0533
4	0.5	0.3	0.232	0.0676
5	1.0	0.4	0.411	0.0108
6	1.2	0.5	0.470	0.0300
7	3.0	0.6	0.795	0.1955
8	3.6	0.7	0.851	0.1511
9	4.0	0.8	0.879	0.0795
10	5.0	0.9	0.929	0.0290

والشكلان الآتيان يعرضان دالة التوزيع العملية مع التوزيع الأسّي والطبيعي الملائم لها على الترتيب، وذلك باستخدام برنامج .Minitab



الشكل (١١، ٩)



الشكل (١١، ٩ ب)

(١١, ٧, ١, ٣) اختبار أندرسون-دارلينغ لجودة التوفيق Anderson-Darling Test for Goodness of Fit

إنَّ اختبار أندرسون-دارلينغ الذي قَدِّم عام 1952 من قبل الرياضياتي والإحصائي الأمريكي أندرسون Theodore Wilbur Anderson (1918-2016) والإحصائي الأمريكي دارلينغ Donald Allan Darling (1915-2014) يُعدُّ بديلاً جيداً عن الاختبارات الإحصائية السابقة عندما نريد الكشف عن مدى ابتعاد توزيع العينة من التوزيع الطبيعي (أو من توزيع وايبول Weibull Distribution) كما هو الحال لدى اختبار كلموغوراف-سميرنوف، ولكنه يتميز عن هذا الاختبار الأخير أنه يُعطي وزناً أكبر لذيول التوزيع. كذلك هو اختبار إحصائي يبيِّن لنا ما إذا كان توزيع بيانات مُعطاة تتوافق مع توزيع احتمالي معيَّن أيضاً، بمعنى أنه يمكن تطبيقه على جميع التوزيعات، ولكن إيجاد جدول القيم الحدية له ليس بالأمر السهل، وهذا الجدول موجود من أجل التوزيع الطبيعي، والطبيعي اللوغاريتمي، والأسّي، ووايبل، وتوزيع غامبل، والتوزيع المنطقي (اللوجستي).

بما أنَّ اختبار أندرسون-دارلينغ لجودة التوفيق (من أجل اختبار ملاءمة توزيع احتمالي ما لتوزيع هذا المجتمع) يستفيد من توزيع معيَّن في حساب القيم الحرجة فإنَّ ذلك ستمنحه ميزة إعطاء الاختبار حساسية أكثر، ولكن العيب في هذا الاختبار هو أنَّ القيم الحرجة يجب أن تحسب من أجل كل توزيع مستخدم على حدة.

فيما يلي سنقدِّم اختبار أندرسون-دارلينغ لتوفيق توزيع احتمالي ما عندما تكون دالة التوزيع النظرية F_o هي دالة التوزيع الطبيعي $N(\mu, \sigma)$ ، وفي حال عدم معرفة المعلمتين μ و σ فإنه يتم تقديرهما من العينة \mathcal{X}_n ، فلو كان $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متغير عشوائي X دالة توزيعه F_X مجهولة، و \mathcal{X}_n عينة من هذا المجتمع، فعندئذ يقوم اختبار أندرسون-دارلينغ على تنفيذ البنود الآتية:

١- وضع الفرضية الابتدائية $H_o: F_X \equiv F_o$ ، وفي حال رفض H_o عند مستوى من الأهمية α علينا القبول بالفرضية البديلة: $H_A: F_X \neq F_o$ ، علماً أنَّ F_o هي دالة التوزيع النظرية التي نفترض أن تكون صحيحة.

٢- نقوم بترتيب قيم البيانات الناتجة عن العينة تصاعدياً ليصبح لها العرض $x_1 > x_2 > \dots > x_i > \dots > x_n$.

٣- تُعرَّف إحصاءة D بالعينة \mathcal{X}_n قيمتها (سنرمز لها بـ **ad**) تحسب باستخدام العلاقة الآتية:

$$\text{ad} := -n + \frac{1}{n} \sum_{i=1}^n (1-2i) [\ln F_o(x_i) + \ln [1-F_o(x_{n-i+1})]] \quad [11,17]$$

٤- تُحسب القيمة الحرجة لهذا الاختبار بالعلاقة الآتية:

$$c = 0.752 \left(1 + \frac{0.75}{n} + \frac{2.25}{n^2} \right)^{-1} \quad [11,18]$$

٥- تُقارن القيمة **ad** مع **c**، فإذا كان:

أ- لدينا $c < \text{ad}$ فعندئذ ترفض الفرضية الابتدائية H_o عند مستوى الأهمية α .

ب- لدينا $c \geq \text{ad}$ فعندئذ تقبل الفرضية الابتدائية H_o عند مستوى الأهمية α .

(١١, ٧, ١, ٣, ١) ملاحظة

بما أنَّ تعيين قيم $F_o(x_i)$ يعتمد على التوزيع الطبيعي ذي المعلمتين μ_o و σ_o فإنَّ تنفيذ الاختبار يدوياً سيتطلب جهداً كبيراً ومطولاً، ولذلك يُفضَّل استخدام البرامج الإحصائية لحساب **ad** ومن ثمَّ مقارنتها مع القيمة الحرجة **c**.

(٢, ٣, ١, ٧, ١١) مثال

بالعودة إلى المثال السابق لننظر إن كان التوزيع الزمني لانهيار عمل دائرة إلكترونية لدى تعرضها لجهد كهربائي أعلى من الجهد المسموح به خاضع للتوزيع الطبيعي أم لا، وذلك عند مستوى من الأهمية قدره $\alpha = 0.05$ ؟

الحل: لدينا من معطيات المثال البيانات الآتية مُقدَّرة بالثانية:

0.5 1 3 3.6 0.3 4 0.1 0.2 5 1.2

ولنختبر الفرضية الابتدائية:

$$H_0 : F_X(x) \equiv F_0(x) = \frac{1}{\sigma_0 \sqrt{2\pi}} e^{-\frac{1}{2} \left(\frac{x - \mu_0}{\sigma_0} \right)^2}$$

مقابل الفرضية البديلة $H_A : F_X(x) \neq F_0(x)$ وذلك عند مستوى الأهمية قدره $\alpha = 0.05$.

لتنفيذ هذا الاختبار علينا تعيين قيم المعلمتين μ_0 و σ_0 ، حيث نعلم أن مُقدَّرا معلمتي المجتمع الطبيعي μ و σ هما $\hat{\mu} = \bar{X}$ و $\hat{\sigma} = S$ (مقدَّرات غير منحازة أيضاً)، ومن المعطيات التي لدينا نجد أن $\hat{\mu} = \bar{X} = 1.89$ وكذلك $\hat{\sigma} = S = 1.83$.

الآن من أجل حساب **ad** سنستخدم الجدول الآتي لتسهيل العمليات الحسابية:

i	x_i	a_i	b_i	c_i	d_i	e_i	f_i	g_i
1	1.2	0.098	-2.319	0.149	0.851	-0.161	-2.48	2.480
2	4.5	0.723	-0.324	0.108	0.892	-0.114	-0.437	1.312
3	0.2	0.195	-1.636	0.126	0.874	-0.135	-1.771	8.854
4	0.1	0.215	-1.535	0.220	0.780	-0.248	-1.784	12.48
5	4.0	0.352	-1.045	0.186	0.814	-0.205	-1.250	11.25
6	0.3	0.177	-1.731	0.352	0.648	-0.433	-2.165	23.81
7	3.6	0.220	-1.514	0.215	0.785	-0.243	-1.757	22.84
8	3.0	0.130	-2.038	0.195	0.805	-0.217	-2.255	33.82
9	1.0	0.108	-2.230	0.723	0.277	-1.286	-3.515	59.76
10	0.5	0.149	-1.904	0.098	0.902	-0.104	-2.007	38.14
Sum	18.4							214.8
Average	1.84							21.48
S.D.	1.738							

علماً أننا استخدمنا الرموز الآتية للمحافظة على حدود الجدول ومظهره:

$$a_i \triangleq F_0(x_i) \quad \& \quad b_i \triangleq \ln F_0(x_i) \quad \& \quad c_i \triangleq F_0(x_{n-i+1}) \quad \& \quad d_i \triangleq 1 - F_0(x_{n-i+1})$$

$$e_i \triangleq \ln[1 - F_0(x_{n-i+1})] \quad \& \quad f_i := b_i + e_i \quad \& \quad g_i := (1 - 2i)f_i$$

فيكون لدينا ما يلي:

$$ad = -n + \frac{1}{n} \sum_{i=1}^n (1 - 2i) [\ln F_0(x_i) + \ln[1 - F_0(x_{n-i+1})]] = 11.48$$

وأما القيمة الحرجة **c** فنجدها تساوي:

$$c = 0.752 \left(1 + \frac{0.75}{n} + \frac{2.25}{n^2} \right)^{-1} = 0.752 \left(1 + \frac{0.75}{10} + \frac{2.25}{100} \right)^{-1} = 0.685$$

ومن ثم يكون لدينا $c = 0.685 < 11.48 = ad$ ، ولذلك علينا القبول بالفرضية الابتدائية H_0 عند مستوى الأهمية $\alpha = 0.05$.

لقد قمنا فيما سبق بتقديم اختبارات لفرضيات تتعلق بمسألة توافق توزيع احتمالي مع توزيع مجتمع إحصائي معطى. فيما يلي سنتابع تقديم اختبارين آخرين ولكن ليس من أجل مجتمعين إحصائيين فقط وإنما من أجل أي عدد من المجتمعات.

(١١, ٧, ٢) اختبارات إحصائية من أجل تجانس التوزيعات Homogeneity Tests of Distributions

لنفترض أنه لدينا $[\Omega_1, \mathcal{S}_1, \mathcal{P}_1]$, $[\Omega_2, \mathcal{S}_2, \mathcal{P}_2]$, ..., $[\Omega_k, \mathcal{S}_k, \mathcal{P}_k]$ مجتمعات مستقلة موصوفة من خلال متغيرات عشوائية X_1, X_2, \dots, X_k على الترتيب، ولنفترض أننا نرغب باختبار الفرضية الابتدائية الآتية عند مستوى من الأهمية α :

$$H_o : F_{X_1}(x) \equiv F_{X_2}(x) \equiv \dots \equiv F_{X_k}(x)$$

مقابل الفرضية البديلة:

H_A : التوزيعات $F_{X_1}, F_{X_2}, \dots, F_{X_k}$ ليست جميعها متطابقة

فعندئذ يقال عن هذا الاختبار إنه اختبار التجانس للمجتمعات $[\Omega_1, \mathcal{S}_1, \mathcal{P}_1]$, $[\Omega_2, \mathcal{S}_2, \mathcal{P}_2]$, ..., $[\Omega_k, \mathcal{S}_k, \mathcal{P}_k]$.

في هذا الكتاب سندرس حالتين فقط، وهما اختبار التجانس للمجتمعات الطبيعية ذات التباين المتساوي، وكذلك اختبار التجانس للمجتمعات البرنولية.

(١١, ٧, ٢, ١) اختبار من أجل تساوي المتوسطات لمجتمعات طبيعية مستقلة

لتكن $[\Omega_1, \mathcal{S}_1, \mathcal{P}_1]$, $[\Omega_2, \mathcal{S}_2, \mathcal{P}_2]$, ..., $[\Omega_k, \mathcal{S}_k, \mathcal{P}_k]$ مجتمعات طبيعية مستقلة تبايناتها متساوية، ولنفترض أننا نرغب باختبار الفرضية الابتدائية $H_o : \mu_1 = \mu_2 = \dots = \mu_k$ عند مستوى من الأهمية قدره α مقابل الفرضية البديلة الآتية:

$$H_A : \exists ! i, j \in \mathbb{N}_k \text{ with } i \neq j \text{ and } \mu_i \neq \mu_j$$

والتي تكتب على النحو الآتي أيضاً:

$$H_A : \mu_1, \mu_2, \dots, \mu_k \text{ ليست جميعها متساوية}$$

فعندئذ للوصول إلى القرار الخاص بهذا الاختبار نقوم بما يلي:

١- نسحب عينات عشوائية من المجتمعات $[\Omega_1, \mathcal{S}_1, \mathcal{P}_1]$, $[\Omega_2, \mathcal{S}_2, \mathcal{P}_2]$, ..., $[\Omega_k, \mathcal{S}_k, \mathcal{P}_k]$ بحجم n_1, n_2, \dots, n_k على الترتيب، ثم نخضع هذه العينات للدراسة المطلوبة، ولنفرض أن كل عينة يمكن أن تخضع إلى m نوع من الدراسات (أو الظواهر، أو المعالجات)، وهذا يعني أن كل عينة يمكن تجزئتها إلى m فئة، وكذلك نتائج هذه الدراسة قدمت وفقاً للجدول الآتي:

الجدول (١١, ٥)

		الدراسة (أو الظاهرة، أو المعالجة)				المجموع
		1	2	m	
العينة	1	n_{11}	n_{12}	n_{1m}	$n_{1\bullet} = n_1$
	2	n_{21}	n_{22}	n_{2m}	$n_{2\bullet} = n_2$
	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
	k	n_{k1}	n_{k2}	n_{km}	$n_{k\bullet} = n_k$
Total		$n_{\bullet 1}$	$n_{\bullet 2}$	$n_{\bullet m}$	n

علماً أن n_{ij} هي قيمة المتغير العشوائي N_{ij} الذي يرصد عدد العناصر من العينة n_i التي تحقق الدراسة j ، وكذلك لدينا:

$$n_{j\bullet} = \sum_{\ell=1}^m n_{j\ell} ; j \in \mathbb{N}_k \quad \& \quad n_{\bullet \ell} = \sum_{j=1}^k n_{j\ell} ; \ell \in \mathbb{N}_m \quad \& \quad n = \sum_{j=1}^k n_{j\bullet} = \sum_{\ell=1}^m n_{\bullet \ell}$$

٢- نقوم بحساب قيمة إحصاءة F معطى بالعلاقة الآتية:

$$F = \frac{k(k-1)}{m(m-1)} \cdot \frac{\sum_{j=1}^m \left(m \sum_{i=1}^k N_{ij} - n \right)^2}{\sum_{i=1}^k \sum_{j=1}^m \left(k N_{ij} - n_{\cdot j} \right)^2} \quad [11,19]$$

٣- نعين القيمة الحرجة للاختبار $f_{1-\alpha}^{[m-1;m(k-1)]}$ من جدول توزيع فيشر $F(m;n)$.

٤- نقارن قيمة الإحصاءة F مع القيمة الحرجة $f_{1-\alpha}^{[m-1;m(k-1)]}$ ، فإذا كان:

أ- لدينا $F \leq f_{1-\alpha}^{[m-1;m(k-1)]}$ فإننا نرفض الفرضية H_0 عند مستوى الأهمية α ، ونقر بقبول الفرضية البديلة H_A .

ب- لدينا $F > f_{1-\alpha}^{[m-1;m(k-1)]}$ فإنه ليس أمامنا إلا القبول بالفرضية H_0 عند مستوى الأهمية α .

إن هذا النوع من الاختبارات يستخدم بكثرة في مجال تصميم وتحليل التجارب Design and Analysis of Experiments.

(١, ١, ٢, ٧, ١١) مثال

في مدينة يوجد أربعة مخابز مركزية B_1, B_2, B_3 و B_4 لإنتاج نوعين من الخبز (الصامولي والريغيف)، ويعمل كل منها بشكل مستقل عن الآخر. فإذا افترضنا أن عملية الإنتاج لهذه الخطوط تتبع التوزيع الطبيعي بمتوسط μ_1, μ_2, μ_3 و μ_4 وبانحراف معياري $\sigma_1, \sigma_2, \sigma_3$ و σ_4 على الترتيب علماً أن $\sigma_1 = \sigma_2 = \sigma_3 = \sigma_4 = \sigma$ ، وقمنا بسحب عينات عشوائية من إنتاج هذه المخابز (مقدرة بالكيلو غرام) بحجم $n_1 = 121$ و $n_2 = 144$ و $n_3 = 169$ و $n_4 = 256$ على الترتيب، موزعة على كل نوع كما في الجدول الآتي:

الجدول (٦, ١١)

المجموع	خبز صامولي	خبز ريغيف	المخبز
121	51	70	B_1
144	44	100	B_2
169	49	120	B_3
256	56	200	B_4
690	200	490	sum

ولنبين إن كان متوسط الإنتاج لهذه المخابز متساو عند مستوى من الأهمية $\alpha = 0.05$ أم لا.

الحل: من أجل ذلك علينا اختيار الفرضية الابتدائية $H_0: \mu_1 = \mu_2 = \mu_3 = \mu_4$ مقابل الفرضية البديلة الآتية:

H_A : المتوسطات μ_1, μ_2, μ_3 و μ_4 ليست جميعها متساوية

وذلك عند مستوى من الأهمية $\alpha = 0.05$.

إن اختبار هذه الفرضية يتطلب منا حساب قيمة الإحصاءة F المعطاة بالعلاقة [11,19]، علماً أنه لدينا $m = 2$ و $k = 4$ ، فنجد

ما يلي:

$$F = \frac{k(k-1)}{m(m-1)} \cdot \frac{\sum_{j=1}^m \left(m \sum_{i=1}^k n_{ij} - n \right)^2}{\sum_{i=1}^k \sum_{j=1}^m \left(k \cdot n_{ij} - n_{\cdot j} \right)^2} = \frac{4(4-1)}{2(2-1)} \cdot \frac{\sum_{j=1}^m \left(2 \sum_{i=1}^k n_{ij} - 690 \right)^2}{\sum_{i=1}^k \sum_{j=1}^m \left(4 \cdot n_{ij} - n_{\cdot j} \right)^2}$$

ومن معطيات المثال نجد:

$$\sum_{j=1}^m \left(2 \sum_{i=1}^k n_{ij} - 690 \right)^2 = (980 - 690)^2 + (400 - 690)^2 = 168200$$

$$\sum_{i=1}^k \sum_{j=1}^m \left(4 \cdot n_{ij} - n_{\bullet j} \right)^2 = (4 \times 70 - 490)^2 + (4 \times 51 - 200)^2 + \dots + (4 \times 200 - 490)^2 + (4 \times 56 - 200)^2 = 149584$$

ومن ثم ينتج لدينا:

$$F = \frac{12}{2} \cdot \frac{168200}{149584} = \frac{2018400}{299168} = 6.747$$

ومن جدول توزيع فيشر نجد $f_{1-\alpha}^{[m-1; m(k-1)]} = f_{0.95}^{[11; 6]} = 5.99$ ومن ثم يكون لدينا:

$$f_{1-\alpha}^{[m-1; m(k-1)]} = 5.99 < 6.747 = F$$

وهذا يعني أننا نقرر برفض الفرضية الابتدائية القائلة بتساوي متوسطات الإنتاج لهذه المخازن ونقبل بالفرضية البديلة H_A عند مستوى الأهمية $\alpha = 0.05$.

(٢، ٢، ٧، ١١) اختبار من أجل تساوي معالم مجتمعات برنولية مستقلة

لتكن $[\Omega_1, \mathcal{S}_1, \mathcal{P}_1], [\Omega_2, \mathcal{S}_2, \mathcal{P}_2], \dots, [\Omega_k, \mathcal{S}_k, \mathcal{P}_k]$ مجتمعات برنولية بمعالم p_1, p_2, \dots, p_k على الترتيب، ولنفترض أننا نرغب في اختبار الفرضية الابتدائية $H_0: p_1 = p_2 = \dots = p_k$ عند مستوى من الأهمية قدره α مقابل الفرضية البديلة الآتية:

المعالم p_1, p_2, \dots, p_k ليست جميعها متساوية: H_A or $H_A: \exists ! i, j \in \mathbb{N}_k$ with $i \neq j$ and $p_i \neq p_j$

فعندئذ للوصول إلى القرار الخاص بهذا الاختبار نقوم بما يلي:

١- نقوم بسحب عينات عشوائية من المجتمعات $[\Omega_1, \mathcal{S}_1, \mathcal{P}_1], [\Omega_2, \mathcal{S}_2, \mathcal{P}_2], \dots, [\Omega_k, \mathcal{S}_k, \mathcal{P}_k]$ بحجم n_1, n_2, \dots, n_k على الترتيب، ثم نخضع هذه العينات للدراسة المطلوبة، فعندئذ من أجل كل $i \in \mathbb{N}_k$ ستوزع نتائج كل عينة n_i في فئتين إحداهما عناصرها تحقق النجاح، وليكن حجمها n_{i1} ، والأخرى عناصرها تفشل في تحقيق المطلوب سنفترض حجمها يساوي n_{i2} ، ومن ثم يمكننا أن نصب نتائج هذه الدراسة في الجدول الآتي:

الجدول (٧، ١١)

	لعينة				المجموع
	1	2	k	
عدد العناصر التي حققت النجاح	n_{11}	n_{21}	n_{k1}	$n_{\bullet 1}$
عدد العناصر التي لم تحقق النجاح	n_{12}	n_{22}	n_{k2}	$n_{\bullet 2}$
Total	n_1	n_2	n_k	n

علماً أن n_{ij} هي قيمة المتغير العشوائي N_{ij} الذي يرصد عدد عناصر العينة ذات الرقم i والمحققة للخاصة ذات الرقم j مع $j \in \{1, 2\}$ و $i \in \mathbb{N}_k$ ، وكذلك لدينا:

$$n_{\bullet 1} = \sum_{i=1}^k n_{i1} \quad \& \quad n_{\bullet 2} = \sum_{i=1}^k n_{i2} \quad \& \quad n = n_{\bullet 1} + n_{\bullet 2} = \sum_{i=1}^k n_i$$

٢- نقوم بحساب قيمة إحصاءة χ^2 معطى بالعلاقة الآتية (وسنرمز لقيمتها بـ χ أيضاً):

$$\chi = n \cdot \sum_{i=1}^k \sum_{j=1}^2 \left[\frac{(n \cdot n_{ij} - n_{\bullet j} n_i)^2}{n_{\bullet j} n_i} \right] \quad [11,20]$$

٣- نستخرج $\chi_{1-\alpha}^{[k-1]}$ التي تمثل القيمة الحرجة لهذا الاختبار من جدول توزيع كاي مربع.

٤- نقارن قيمة الإحصاءة χ مع القيمة الحرجة $\chi_{1-\alpha}^{[k-1]}$ ، فإذا كان:

أ- لدينا $\chi \leq \chi_{1-\alpha}^{[k-1]}$ فعندئذ نرفض الفرضية H_0 ، ومن ثمَّ القبول بالفرضية البديلة H_A عند مستوى الأهمية α .

ب- لدينا $\chi > \chi_{1-\alpha}^{[k-1]}$ فعندئذ ليس أمامنا إلاَّ القبول بالفرضية الابتدائية H_0 عند مستوى الأهمية α .

(١، ٢، ٢، ٧، ١١) مثال

دُكر أنَّ مرضاً جرثومياً يصيب الأغنام يحتاج منطقة رعوية تعيش فيها قطعان من الأغنام، وكإجراء وقائي ضد هذا المرض الجرثومي تمَّ إعطاء اللقاح إلى خمسة قطعان من الأغنام H_1, H_2, H_3, H_4, H_5 (قطع الأغنام الواحد لا يقل عن 500 رأس) منفصلة ومتباعدة بعضها عن بعض (أي لدينا مجتمعات مستقلة)، وبعد فترة من الزمن سحبت عينات عشوائية من هذه القطعان الخمسة بحجم $n_1 = 85, n_2 = 77, n_3 = 95, n_4 = 118, n_5 = 95$ على الترتيب، فوجد أنَّ عدد الأغنام المصابة في هذه العينات على الترتيب هي 3، 2، 7، 13 و 2.

السؤال هنا: هل تشير هذه النتائج إلى أنَّ نسب الإصابات في هذه القطعان الخمسة متساوية وذلك عند مستوى من الأهمية قدره $\alpha = 0.05$ ، وهل يبقى القرار نفسه من أجل $\alpha = 0.01$ ؟

الحل: للإجابة على هذا السؤال علينا اختيار الفرضية الابتدائية $H_0: p_1 = p_2 = p_3 = p_4 = p_5$ مقابل الفرضية البديلة:

المعالم p_1, p_2, \dots, p_k ليست جميعها متساوية: H_A

وذلك عند مستوى من الأهمية $\alpha = 0.05$ ، وبعد ذلك سنعيد دراسة الاختبار نفسه من أجل مستوى الأهمية $\alpha = 0.01$.

الآن، ومن أجل تبسيط تنفيذ هذا الاختبار سنصب نتائج دراستنا في الجدول الآتي:

الجدول (٨، ١١)

		القطيع					المجموع
		H_1	H_2	H_3	H_4	H_5	
الحالة	سليمة	82	75	93	105	88	443
	مصابة	3	2	2	13	7	27
Total		85	77	95	118	95	470

ومن ثمَّ يكون للإحصاءة χ المعطى بالعلاقة [11,20] القيمة الآتية:

$$\chi = n \cdot \sum_{i=1}^5 \sum_{j=1}^2 \left[\frac{(n \cdot n_{ij} - n_{\bullet j} n_i)^2}{n_{\bullet j} n_i} \right] = 11.025$$

حيث تُعَيَّن القيمة الحرجة $\chi_{1-\alpha}^{[k-1]}$ من جدول توزيع كاي مربع، فنجدها من أجل $\alpha = 0.05$ تساوي:

$$\chi_{1-\alpha}^{[k-1]} = \chi_{0.95}^{[4]} = 9.488$$

ومن ثم ينتج لدينا أن:

$$\chi_{1-\alpha}^{[k-1]} = 9.488 < 11.025 = \chi$$

وهذا يعني رفض الفرضية الابتدائية H_0 عند مستوى الأهمية $\alpha = 0.05$ ، أي إنَّ نسب الإصابات في هذه القطعان الخمسة ليست متساوية عند مستوى من الأهمية $\alpha = 0.05$.

أما لتعيين القيمة الحرجة $\chi_{1-\alpha}^{[k-1]}$ من أجل $\alpha = 0.01$ فنجدها من جدول توزيع كاي مربع أنها تساوي:

$$\chi_{1-\alpha}^{[k-1]} = \chi_{0.99}^{[4]} = 13.277$$

ومن ثم ينتج لدينا:

$$\chi_{1-\alpha}^{[k-1]} = 13.277 > 11.025 = \chi$$

وفي هذه الحالة ليس أمامنا إلا أن نقبل بالفرضية الابتدائية H_0 عند مستوى الأهمية $\alpha = 0.01$ ، أي إنَّ نسب الإصابات في هذه القطعان الخمسة متساوية عند مستوى من الأهمية $\alpha = 0.01$.

(١١, ٧, ٣) اختبار استقلال ظاهرتين (أو متغيرين) Independence Test of two Phenomenon (or Variables)

ليكن $[\Omega, \mathcal{S}, \mathcal{P}]$ مجتمعاً موصوفاً من خلال متجه عشوائي ثنائي البعد $\mathbb{X}_2 = (X_1, X_2)$ ، فعندئذ كل عنصر من عناصر المجتمع سيكون خاضعاً لصفيتين (أو توزيعين) أحدهما ذو صلة بتوزيع X_1 والآخر ذو صلة بتوزيع X_2 ، فلو افترضنا أن أي عنصر من المجتمع يمكن له أن يتواجد في إحدى الحالات S_1, S_2, \dots, S_k وفقاً للظاهرة الممثلة بـ X_1 ، وكذلك يمكن له أن يوجد في إحدى الحالات Z_1, Z_2, \dots, Z_ℓ وفقاً للظاهرة الممثلة بـ X_2 . عندئذ يمكننا صَبَّ نتائج دراسة عينة من هذا المجتمع في الجدول الآتي:

الجدول (١١, ٩)

		حالات المتغير X_1				المجموع
		S_1	S_2	S_k	
حالات المتغير X_2	Z_1	n_{11}	n_{12}	n_{1k}	$n_{1\bullet}$
	Z_2	n_{21}	n_{22}	n_{2k}	$n_{2\bullet}$
	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
	Z_ℓ	$n_{\ell 1}$	$n_{\ell 2}$	$n_{\ell k}$	$n_{\ell \bullet}$
Total		$n_{\bullet 1}$	$n_{\bullet 2}$	$n_{\bullet k}$	n

وهذا الجدول يُدعى **جدول الاقتران**، علماً أنَّ n_{ij} هي قيمة المتغير العشوائي N_{ij} الذي يرصد عدد العناصر من العينة التي تُحقق الحالة S_i و Z_j معاً، وكذلك لدينا:

$$n_{i\bullet} = \sum_{j=1}^k n_{ij} \quad ; i \in N_\ell \quad \& \quad n_{\bullet j} = \sum_{i=1}^\ell n_{ij} \quad ; j \in N_k$$

والآن من أجل اختبار الفرضية الابتدائية:

$$H_0 : X_1 \text{ مستقل عن } X_2$$

مقابل الفرضية البديلة:

$H_A: X_1$ غير مستقل عن X_2

وذلك عند مستوى من الأهمية α ، فإنه علينا تنفيذ الخطوات الآتية:

١- نقوم بحساب قيمة الإحصاء الآتية (وسنرمز لقيمتها بـ u):

$$U = \sum_{j=1}^k \sum_{i=1}^{\ell} \frac{(N_{ij} - E_{ij})^2}{E_{ij}} \quad [11,21-a]$$

علماً أن المقادير E_{ij} تُدعى التكرارات المتوقعة Expected Frequencies وتحسب بالعلاقة الآتية:

$$E_{ij} = \frac{n_{i \cdot} \cdot n_{\cdot j}}{n} \quad ; i \in N_{\ell}, j \in N_k \quad [11,21-b]$$

٢- نعين القيمة $\chi^2_{1-\alpha}$ من جدول توزيع كاي مربع، علماً أن $v = (k-1) \cdot (\ell-1)$.

٣- نقارن بين القيمتين u و $\chi^2_{1-\alpha}$ ، فإذا كان:

أ- لدينا $\chi^2_{1-\alpha} \leq u$ ، فعندئذ ترفض الفرضية الابتدائية H_0 ونقبل بالفرضية البديلة H_A عند مستوى الأهمية α .

ب- لدينا $\chi^2_{1-\alpha} > u$ فإنه علينا القبول بالفرضية الابتدائية H_0 عند مستوى الأهمية α .

(١، ٣، ٧، ١١) مثال

أُخذت عينة بحجم 160 جهازاً من أجهزة الحواسيب المستعملة بمعدل 15 ساعة عمل يومياً في درجات حرارة متباينة، فوجدنا أن الأجهزة التي اختل عملها مُعطاة كما في الجدول الآتي:

الجدول (١٠، ١١.أ)

		درجة الحرارة المثوية التي عمل فيها الحاسوب			المجموع
		25	35	40	
مدة استخدام الجهاز بالشهر	6	3	5	7	15
	12	5	9	15	29
	24	8	13	20	41
	36	14	23	38	75
Total		30	50	80	160

فهل تدل هذه النتائج على أن تأثير درجة الحرارة على الأجهزة غير مستقلة عن عمر الجهاز عند مستوى الأهمية قدره $\alpha = 0.05$ ، وهل يبقى القرار نفسه من أجل $\alpha = 0.01$ ؟

الحل: من أجل الإجابة على هذا السؤال علينا اختبار الفرضية الابتدائية:

تأثير تغيرات درجة الحرارة على الجهاز غير مستقلة عن عمر الجهاز: H_0

مقابل الفرضية البديلة:

تأثير تغيرات درجة الحرارة على الجهاز لا علاقة لها بعمر الجهاز: H_A

وذلك عند مستوى الأهمية $\alpha = 0.05$.

الآن، من أجل حساب قيمة الإحصاء U المعطاة بالعلاقة [11,21-a] سنقوم بحساب التكرارات المتوقعة E_{ij} باستخدام

العلاقة [11,21-b] فنجدها كما في الجدول الآتي الذي يدعى جدول التكرارات المتوقعة Table of Expected Frequencies:

الجدول (١٠، ١١.ب)

		قيم i			المجموع
		1	2	3	
قيم j	1	2.813	4.688	7.500	قيم E_{ij}
	2	5.438	9.063	14.500	
	3	7.688	12.813	20.500	
	4	14.063	23.438	37.500	

ولحساب القيم $\frac{(n_{ij} - E_{ij})^2}{E_{ij}}$ سنستخدم الجدول الآتي:

الجدول (١٠، ١١.ج)

		قيم i			المجموع
		1	2	3	
قيم j	1	0.01243	0.02077	0.03333	0.06653
	2	0.03528	0.00044	0.01724	0.05296
	3	0.01266	0.00273	0.0122	0.02759
	4	0.00028	0.00819	0.00667	0.01513
		قيم $(n_{ij} - E_{ij})^2 / E_{ij}$			0.16193

فيكون لدينا ما يلي:

$$u = \sum_{j=1}^4 \sum_{i=1}^3 \frac{(n_{ij} - E_{ij})^2}{E_{ij}} = 0.162$$

علماً أنَّ عدد درجات الحرية v يساوي $v = (k - 1)(\ell - 1) = 2 \times 3 = 6$ ، وأما لتعيين القيمة الحرجة $\chi_{1-\alpha}^{[v]}$ فنجدها باستخدام جدول توزيع كاي مربع أنَّها:

أ- من أجل $\alpha = 0.05$ تساوي $\chi_{1-\alpha}^{[v]} = \chi_{0.95}^{[6]} = 12.592$ ، ومن ثمَّ ينتج لدينا:

$$\chi_{1-\alpha}^{[v]} = 12.592 > u = 0.162$$

وفي هذه الحالة ليس أمامنا إلاَّ القبول بالفرضية الابتدائية H_0 عند مستوى الأهمية $\alpha = 0.05$ ، أي إنَّ تأثير تغيُّرات درجة الحرارة على الجهاز غير مستقلَّة عن عمر الجهاز عند مستوى من الأهمية $\alpha = 0.05$.

ب- من أجل $\alpha = 0.01$ تساوي $\chi_{1-\alpha}^{[v]} = \chi_{0.99}^{[6]} = 16.812$ ، ومن ثمَّ ينتج لدينا أنَّ:

$$\chi_{1-\alpha}^{[v]} = 16.812 > u = 0.162$$

وفي هذه الحالة علينا القبول بالفرضية الابتدائية H_0 أيضاً عند مستوى الأهمية $\alpha = 0.01$.

فيما يلي نقدِّم بعض التطبيقات على استخدام برنامج Minitab في مجال اختبار الفرضيات.

(١١,٨) تطبيقات**Applications****(١١,٨,١) تطبيق**

قامت شركة مقاولات بنصب أعمدة كهرباء على طريق عام، وقد زعمت أنها على ثقة قدرها 95% أن متوسط انزياحات أعمدتها التي قامت بنصبها معدوم (يساوي الصفر)، بانحراف معياري لا يتجاوز ميليمتراً واحداً فقط. للتحقق من زعم هذه الشركة اختيرت عينة عشوائية بحجم 49 عموداً من الأعمدة التي نصبها هذه الشركة، ومن ثم قيس مقدار الانزياح (الأخطاء) لهذه الأعمدة عن الموضع المخصص لها باستخدام أجهزة دقيقة، فكانت لدينا البيانات الآتية مقدرة بالميليمتر (وسنطلق عليها اسم Error في هذه الدراسة):


2.1	-0.5	-1.6	-0.8	-0.7	2.1	-1.1	1.2	-1.4	0.4	0.7	-2.4	
-0.9	-0.7	-1.6	-0.7	-1.5	-0.2	-0.8	-0.6	-0.1	-0.6	-0.8	-0.2	
1.8	0.2	0.7	1.9	0.3	0.9	0.7	-0.9	1.0	0.2	-0.2	0.8	
-0.4	0.1	0.4	-2.4	2.4	0.3	-0.2	-0.2	-0.2	-0.1	0	0.7	0.4

علماً أن إشارة الناقص تشير إلى انزياح العمود نحو اليسار في حين تشير إشارة الموجب إلى انزياح العمود نحو اليمين. والآن، لنختبر الفرضية الابتدائية القائلة إن متوسط مجتمع الأخطاء المرتكبة في نصب الأعمدة يساوي الصفر عند مستوى الأهمية $\alpha = 0.05$.

إذاً علينا اختبار الفرضية الابتدائية $H_0: \mu = \mu_0 = 0$ مقابل الفرضية البديلة $H_A: \mu \neq \mu_0 = 0$ وذلك عند مستوى من الأهمية قدره $\alpha = 0.05$.

من أجل ذلك لننظر أولاً إن كان توزيع هذه البيانات طبيعياً أو قريباً من الطبيعي، فنجد باستخدام برنامج Minitab أن شكل مدرجه التكراري المقدم في الشكل الآتي قريب من الطبيعي (مع مقارنته مع التوزيع الطبيعي)، ويمكن الوصول إليه وفقاً للخطوات الآتية (شرحت في نهاية الفصل السابق):

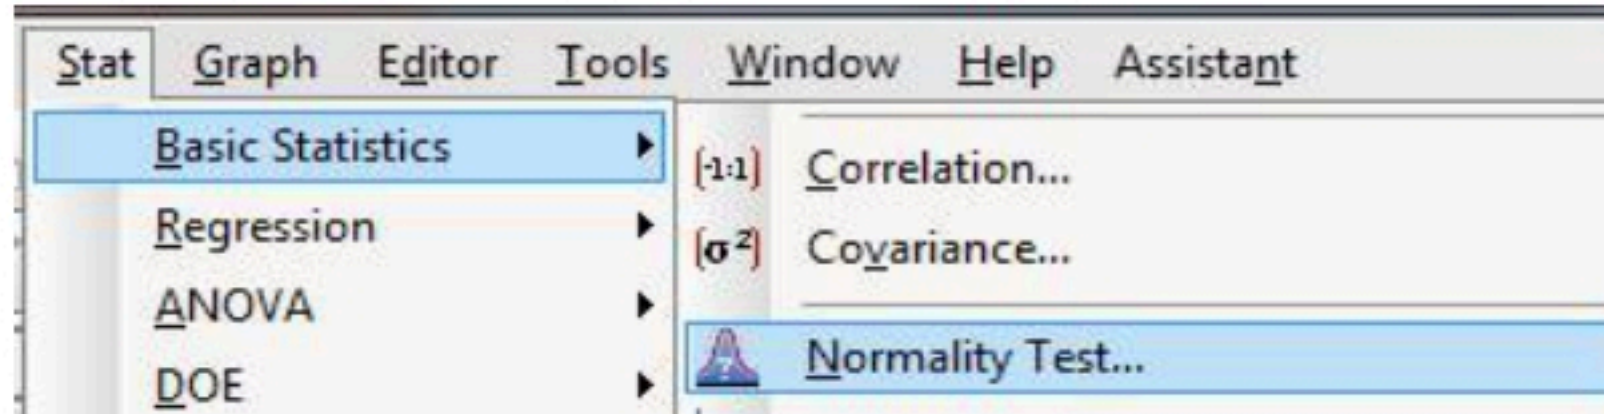
Graph → Histogram → With Fit → Graph variables → In free space for Graph Variables Insert Error ومن ثم **OK**، يمكن الدخول إلى الأيقونات الأخرى قبل الضغط على موافق (OK) لإجراء بعض التعديلات حسب طبيعة الدراسة ومتطلباتها.



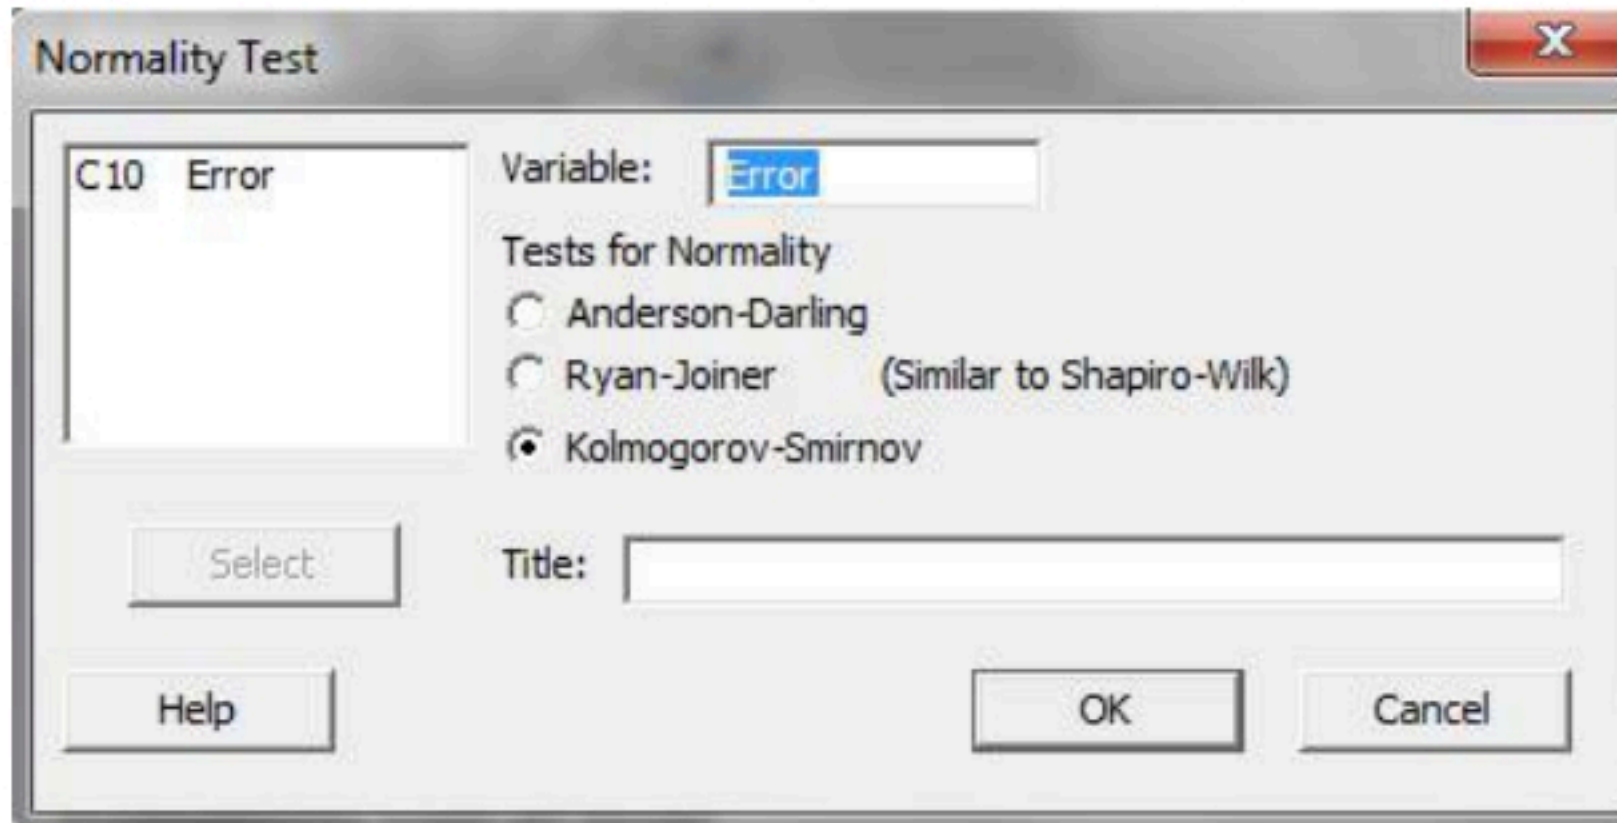
حيث نلاحظ بالفعل أن المدرج التكراري يبدى تقارباً جيداً مع منحنى دالة الكثافة الاحتمالية للتوزيع الطبيعي، ويزودنا هذا العرض

بقيمة المتوسط والانحراف المعياري للبيانات المقدّمة، حيث لدينا $\bar{x} = -0.1282 \text{ mm}$ و $s = 1.093 \text{ mm}$ ، وأما من أجل اختبار إن كانت هذه البيانات تقبل التوزيع الطبيعي كتوزيع مناسب فعلاً فإننا نجد باستخدام اختبار كلموغوراف-سميرنوف في برنامج Minitab ما يلي:


Stat → Basic Statistics → Normality Test → Insert Error in free space for Variable → For Hypothesis test activation Kolmogorov-Smirnov → OK.



ثم الخطوة التالية:



فنحصل على الشكل الآتي الذي يوضح أنّ البيانات تقبل التوزيع الطبيعي (المعياري من أجل مثالنا هذا) عند مستوى الأهمية $\alpha = 0.05$ ، وذلك لأنّ القيمة المحسوبة **P-value** أكبر من 0.150 وهذه القيمة الأخيرة أكبر من مستوى الأهمية $\alpha = 0.05$ التي تعني قبول الفرضية القائلة إنّ البيانات تقبل التوزيع الطبيعي كتوزيع ملائم عند مستوى الأهمية $\alpha = 0.05$.




علمًا أنَّ **P-value** (ويدعوها البعض "القيمة المحسوبة **P**" في حين يدعوها آخرون "القيمة الاحتمالية **P**") تُحدد مدى ملائمة رفض الفرضية الابتدائية في دراسة اختبار الفرضيات، وأما مجموعة القيم التي تنتمي إليها هذه القيمة فهي الفترة $[0, 1]$ ، ومعظم البرامج الإحصائية تقدمها في تقاريرها لدى اختبار الفرضيات الإحصائية. أما تفسير هذه القيمة فيتم على النحو الآتي:

كلما صغرت القيمة الاحتمالية **P** أدى ذلك إلى صغر الخطأ في احتمال رفض الفرضية الابتدائية، وعلى العموم فإذا كانت قيمة **P-value** أصغر من قيمة مستوى الأهمية α فإن ذلك يشير إلى رفض الفرضية الابتدائية H_0 عند مستوى الأهمية α ، وفي حال العكس يكون القبول لـ H_0 .

الآن، وبالعودة إلى مثالنا يمكننا ملاحظة تقارب النقاط الممثلة لقيم العينة من المستقيم الناتج عن خطية التوزيع الطبيعي المرسوم على لوحة مقسمة تدعى لوحة التوزيع الطبيعي، حيث منحني دالة التوزيع الطبيعي يبدو مستقيماً على هذه اللوحة (بسبب عملية الخطية على العلاقة التي تعطي دالة الكثافة للتوزيع والتي وضحنا إياها لدى دراسة الانحدار الخطي)، وهذا يعني أنَّ البيانات تتوزع طبيعياً على وجه التقريب عند مستوى الأهمية المفترض.

كذلك لو استخدمنا اختبار أندرسون-دارلينغ فإننا سنحصل على النتيجة نفسها حيث لدينا الشكل الآتي لهذا الاختبار.



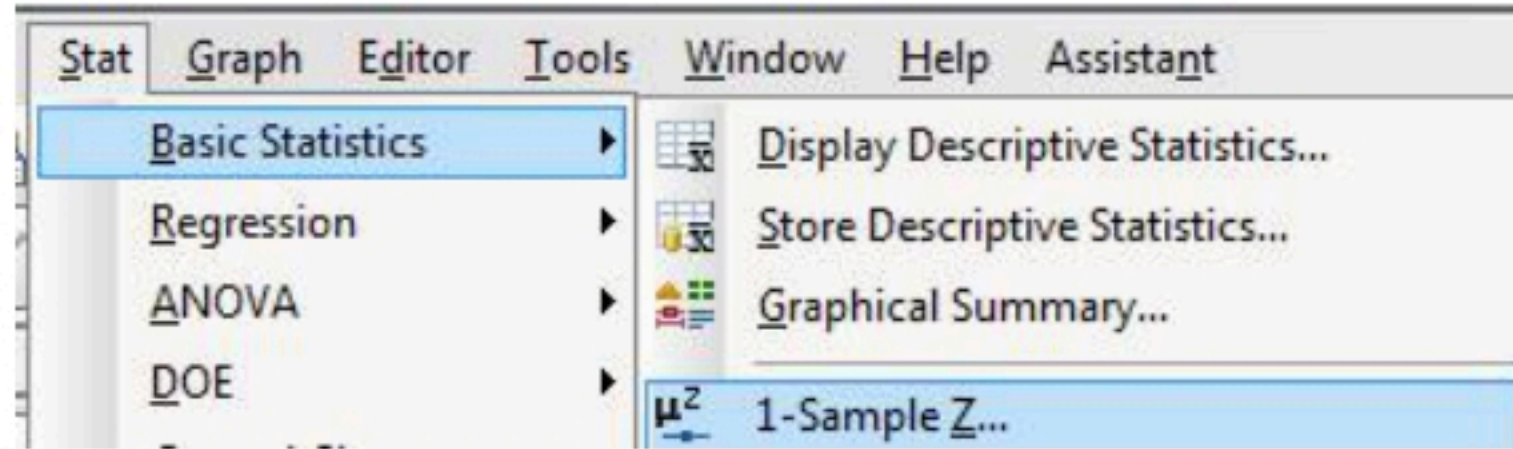
حيث نلاحظ هنا أنَّ $P\text{-value} = 0.797 > 0.05 = \alpha$ والذي يشير إلى قبول الفرضية الابتدائية القائلة إنَّ للبيانات المُعطاة توزيعاً طبيعياً عند مستوى الأهمية $\alpha = 0.05$.

والآن من أجل اختبار الفرضية الابتدائية المقدّمة سابقاً نعلم أنَّه علينا أن نميز بين حالتين هما:

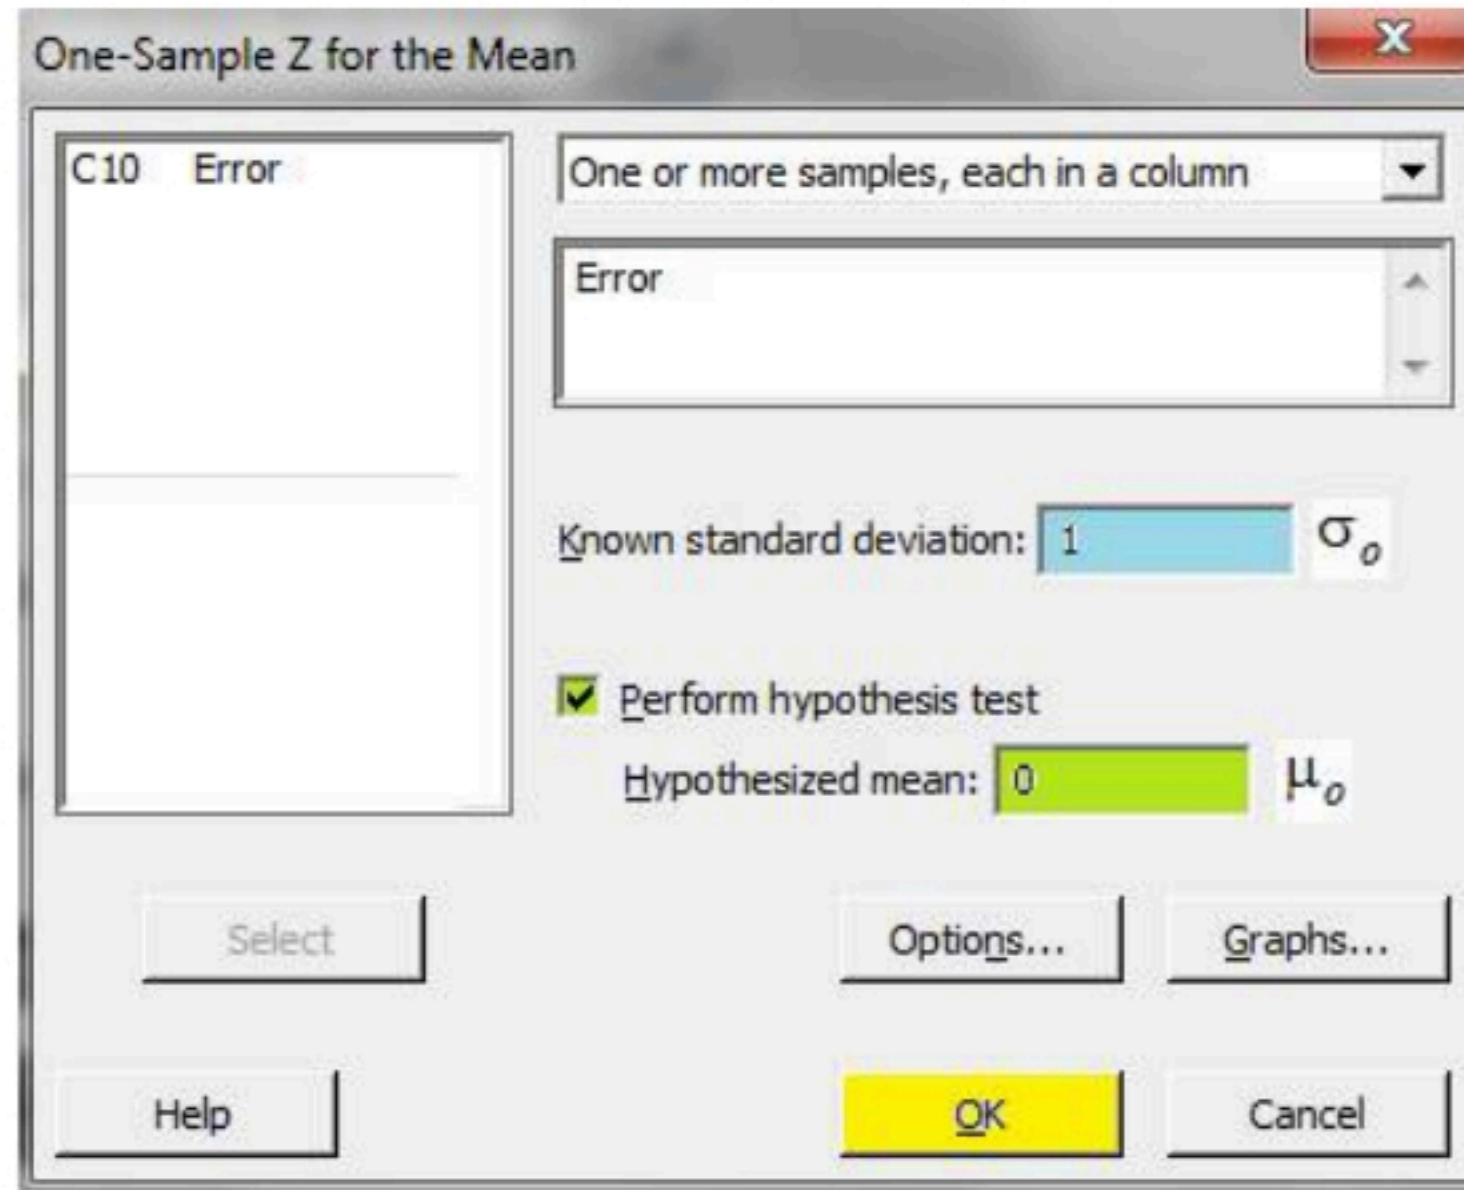
أ - إذا افترضنا أنَّ الانحراف المعياري للمجتمع معلوم ويساوي $\sigma = \sigma_0 = 1$ (أي أخذنا بقيمة الانحراف المعياري الذي قدّمته الشركة)، فعندئذ نتبع الخطوات الآتية (مستخدمين التوزيع الطبيعي):

Stat → Basic Statistics → 1-Sample Z → Insert Error in free space → For Known standard deviation insert value 1 → For Hypothesized mean insert value 0 → OK.

يمكنك هنا تغيير مستوى الأهمية α من أيقونة Options.



ثم الخطوة التالية:



ومن ثم تفعيل Perform hypothesis test مع إدخال المعلومات المطلوبة لتنفيذ الاختبار (قيمتي الانحراف المعياري σ_o والمتوسط μ_o للمجتمع)، وبعد ذلك الضغط على OK فنحصل على التقرير الآتي الذي يحتوي على 95% فترة ثقة للمتوسط μ بالإضافة لنتيجة الاختبار المنشود.

One-Sample Z: Error

Test of $\mu = 0$ vs $\neq 0$

The assumed standard deviation = 1

Variable	N	Mean	StDev	SE Mean	95% CI	Z	P
Error	49	-0.128	1.093	0.143	(-0.408; 0.152)	-0.90	0.370

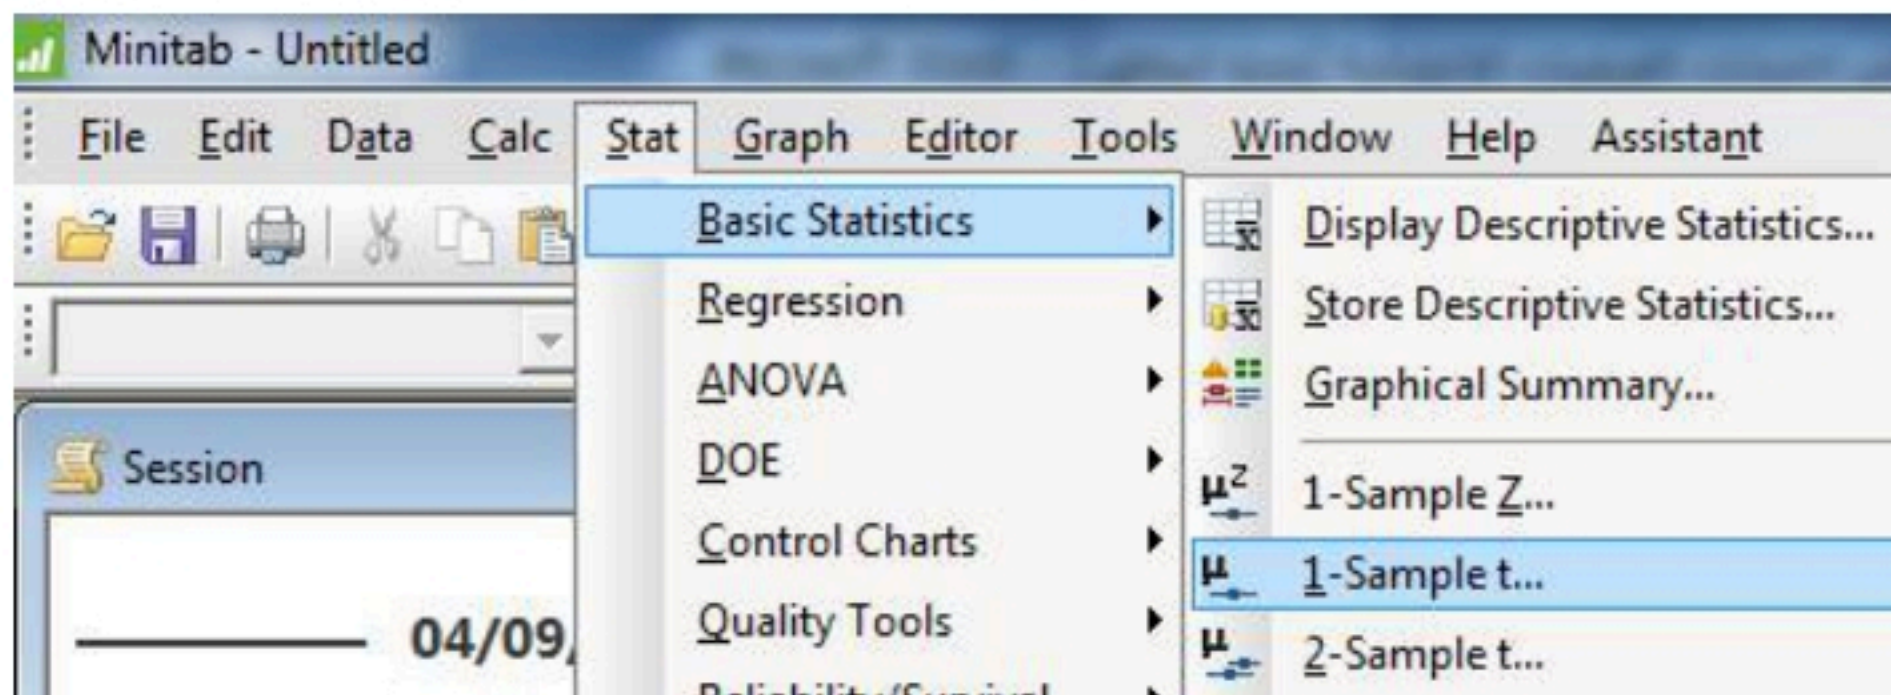
حيث لدينا من هذا التقرير قيمة الإحصاء $z = -0.90$ ، وكذلك نعلم أن (من جدول التوزيع الطبيعي المعياري) أن $z_{1-\frac{\alpha}{2}} = z_{0.975} = 1.96$ ، ولذلك يكون لدينا:

$$-1.96 < z = \frac{\bar{x} - \mu_o}{\sigma_o} \sqrt{n} = -0.90 < 1.96$$

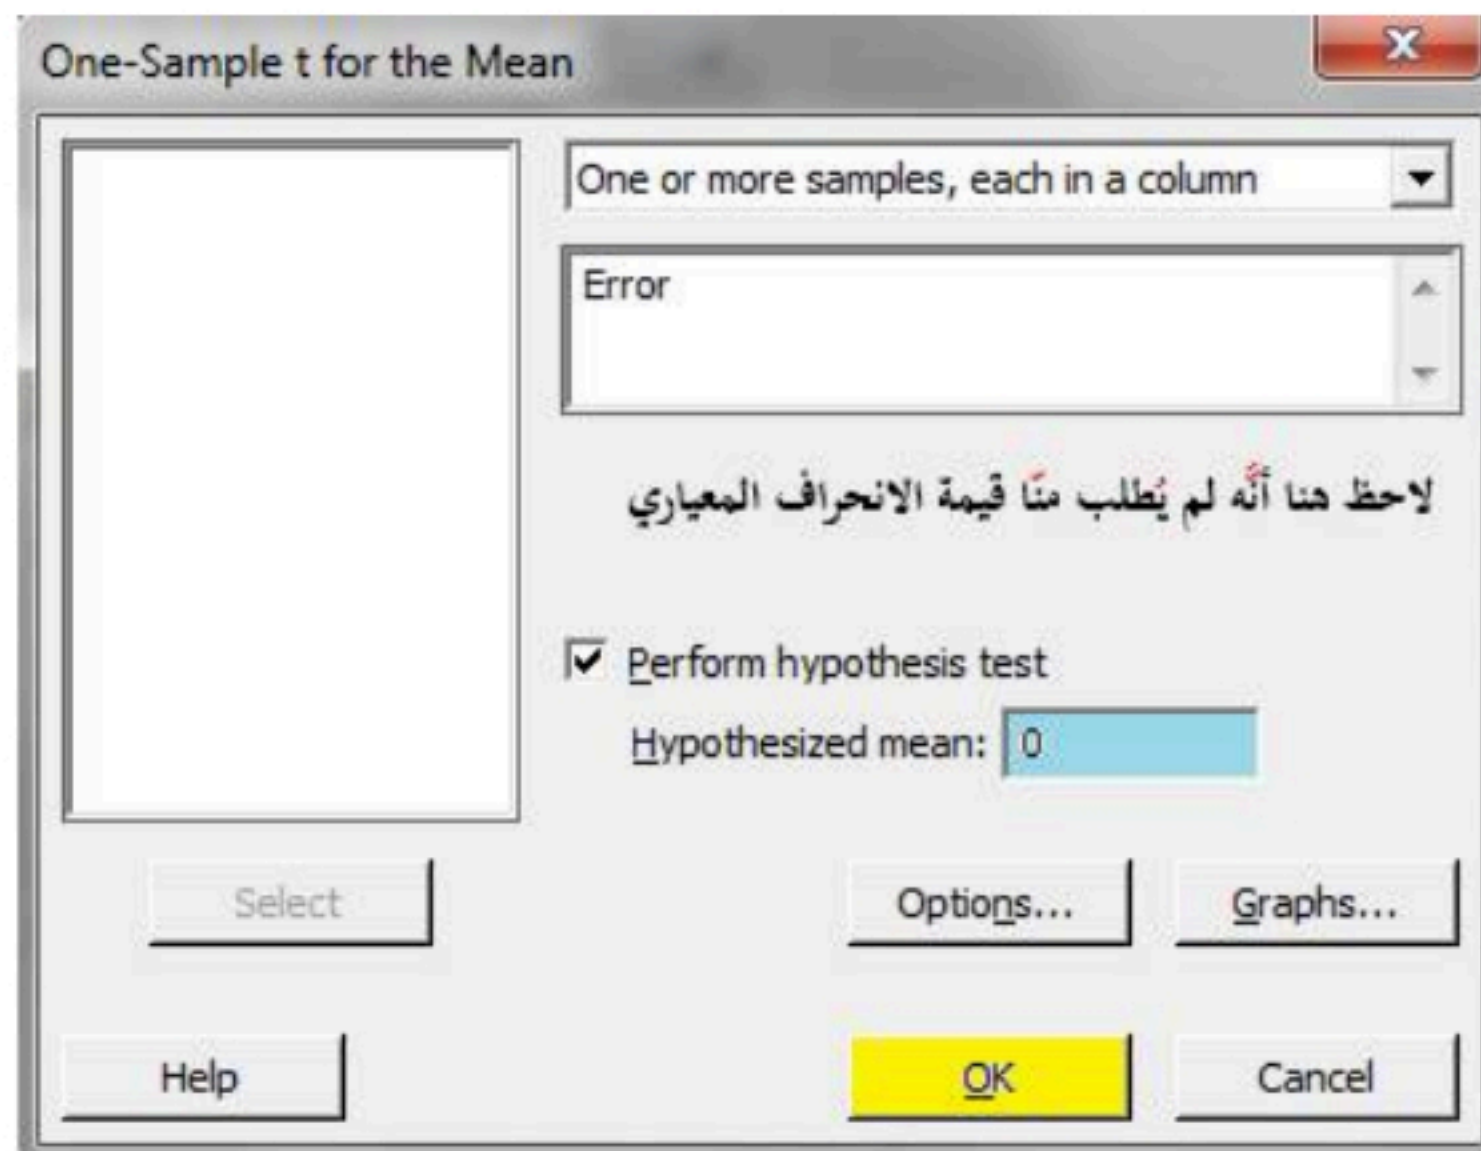
وهذا يعني أنه علينا القبول بالفرضية الابتدائية H_0 عند مستوى الأهمية $\alpha = 0.05$. إن هذه النتيجة موجودة في التقرير أيضاً حيث لدينا القيمة المحسوبة **P-value** تساوي 0.370 وهي أكبر من مستوى الأهمية $\alpha = 0.05$ التي تعني قبول الفرضية الابتدائية H_0 عند مستوى الأهمية $\alpha = 0.05$.

ب- إذا افترضنا أن الانحراف المعياري للمجتمع مجهولاً $\sigma = ?$ ، فعندئذ نتبع الخطوات الآتية (مستخدمين توزيع t - ستودنت-):

Stat → Basic Statistics → 1-Sample t → Known standard deviation → OK



ثم الخطوة التالية:



ومن ثم تفعيل Perform hypothesis test مع إدخال المعلومات المطلوبة لتنفيذ الاختبار (قيمة μ_0 فقط)، وبعد ذلك الضغط على OK فنحصل على التقرير الآتي الذي يحتوي على 95% فترة ثقة للمتوسط μ بالإضافة لنتيجة الاختبار المنشود.

One-Sample T: Error

Test of $\mu = 0$ vs $\neq 0$

Variable	N	Mean	StDev	SE Mean	98% CI	T	P
Error	49	-0.128	1.093	0.156	(-0.504; 0.248)	-0.82	0.416

ف نجد من هذا التقرير أن قيمة الإحصاء T تساوي -0.82 ، ولكن لدينا $t_{1-\frac{\alpha}{2}}^{[n-1]} = t_{0.975}^{[48]} = 2.010$ ، ومن ثم يكون لدينا:

$$-2.010 < t = \frac{\bar{x} - \mu_0}{s} \sqrt{n} = -0.82 < 2.010$$

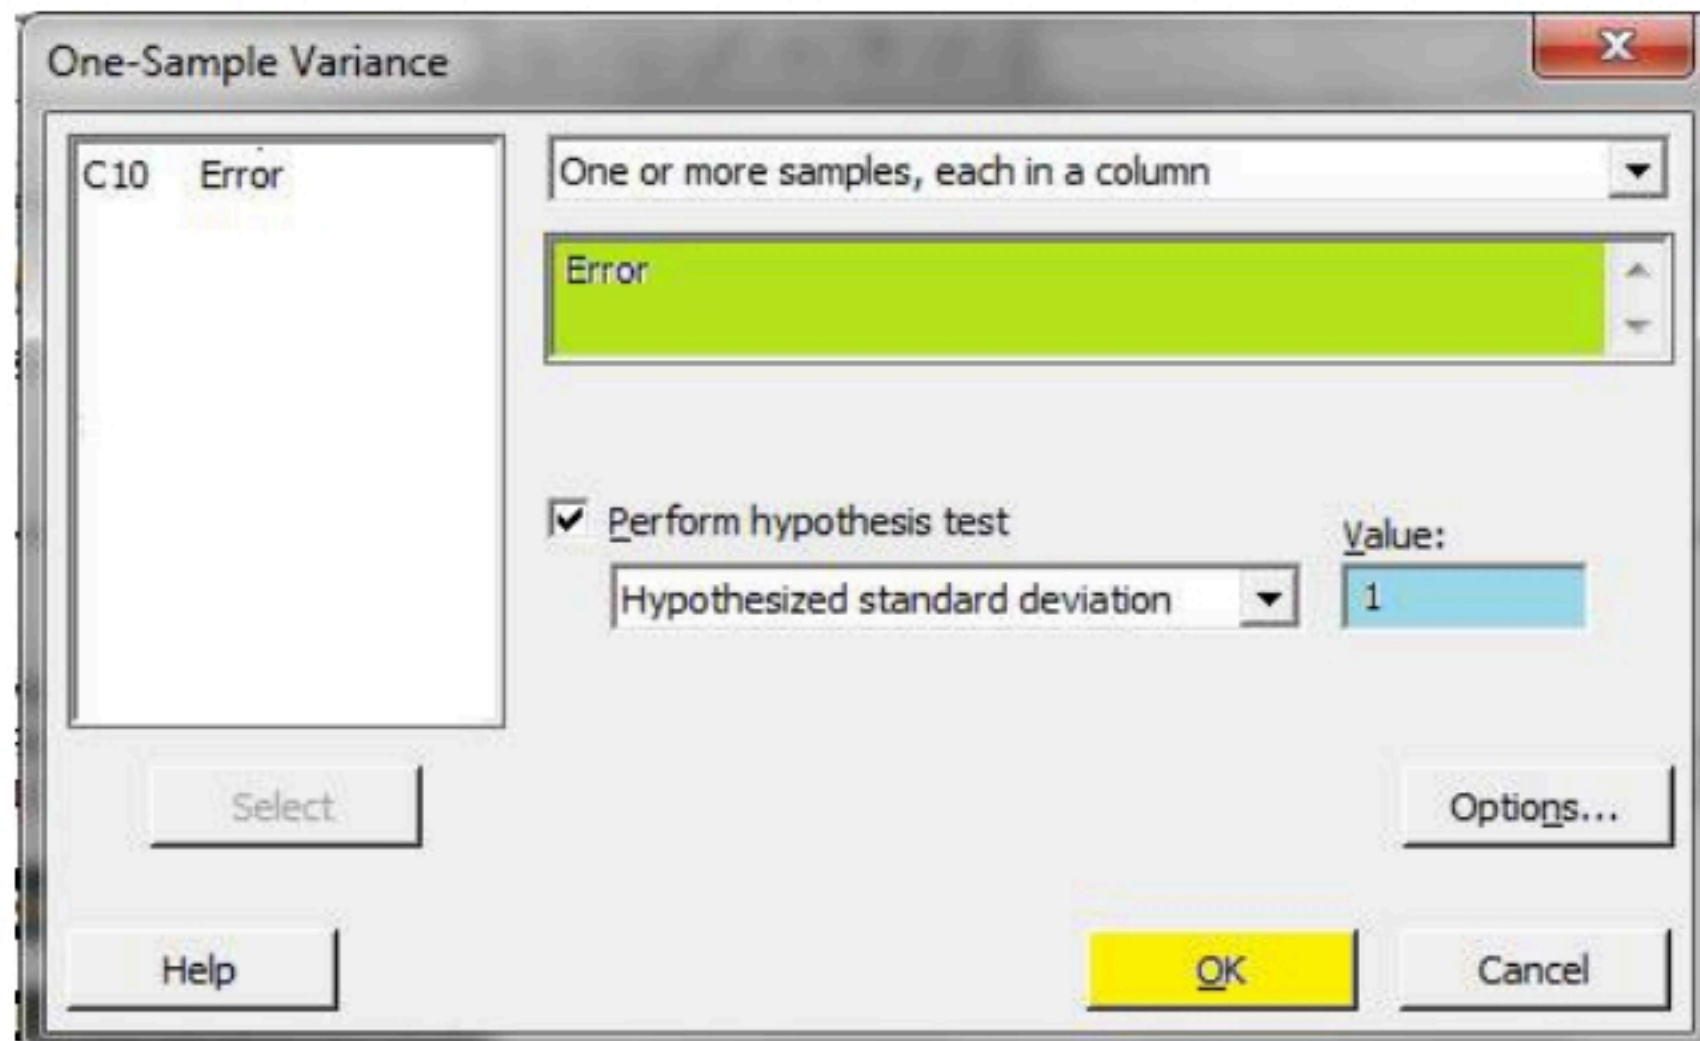
وهذا يعني أنه علينا القبول بالفرضية الابتدائية H_0 في هذه الحالة أيضاً، وذلك عند مستوى الأهمية $\alpha = 0.05$ ، وهذه النتيجة موجودة في التقرير أيضاً حيث لدينا القيمة المحسوبة **P-value** تساوي 0.416 وهي أكبر من مستوى الأهمية $\alpha = 0.05$ التي تعني قبول الفرضية الابتدائية H_0 عند مستوى الأهمية $\alpha = 0.05$.

(١١, ٨, ١, ١) ملاحظة

إذا كنا نرغب في تغيير مستوى الأهمية فإنه يمكننا ذلك بالتعديل على هذه القيمة بحسب ما تم شرحه في نهاية الفصل السابق.

الآن، ومن أجل اختبار الفرضية الابتدائية القائلة إن تباين مجتمع الأخطاء المرتكبة في نصب الأعمدة يساوي الواحد (القيمة التي قدمتها الشركة) عند مستوى الأهمية $\alpha = 0.05$ ، فإنه علينا اختبار الفرضية الابتدائية $H_0: \sigma^2 = \sigma_0^2 = 1$ مقابل الفرضية البديلة $H_A: \sigma^2 \neq \sigma_0^2 = 1$ وذلك عند مستوى من الأهمية قدره $\alpha = 0.05$ ، ولأجل ذلك نتبع الخطوات الآتية:

Stat → Basic Statistics → 1Variance → Insert Error in free space → OK.



ف نحصل على التقرير الآتي (تم التعديل على طريقة عرض التقرير) الذي يحتوي نتيجة الاختبار المطلوب بالإضافة إلى 95% فترة ثقة لكل من الانحراف المعياري σ والتباين σ^2 لمجتمع البيانات المقدمة.

Test and CI for One Variance: Error

Method

Null hypothesis $\sigma = 1$ & Alternative hypothesis $\sigma \neq 1$

The chi-square method is only for the normal distribution.

The Bonett method is for any continuous distribution.

Statistics

Variable N St Dev Variance

Error 49 1.09 1.19

95% Confidence Intervals

Variable Method

Error Chi-Square

Bonett

CI for

St Dev

(0.91; 1.37)

(0.91; 1.37)

CI for

Variance

(0.83; 1.86)

(0.82; 1.88)

Test

Variable Method

Error Chi-Square

Statistic

57.34

DF

48

P-Value

0.335

حيث نجد من هذا التقرير أن قيمة الإحصاء χ^2 تساوي $\chi^2 = \frac{(n-1)s^2}{\sigma_o^2} = 57.34$ ، ولكن لدينا:

$$\chi_{\frac{\alpha}{2}}^{[n-1]} = \chi_{0.025}^{[48]} \approx \frac{\chi_{0.025}^{[50]} + \chi_{0.025}^{[45]}}{2} = \frac{28.366 + 32.357}{2} = 30.3615$$

$$\chi_{1-\frac{\alpha}{2}}^{[n-1]} = \chi_{0.975}^{[48]} \approx \frac{\chi_{0.975}^{[50]} + \chi_{0.975}^{[45]}}{2} = \frac{65.410 + 71.420}{2} = 68.415$$

ومن ثم يكون $30.3615 < \chi^2 < 68.415$ ، وهذا يعني أنه علينا القبول بالفرضية الابتدائية H_o عند مستوى الأهمية $\alpha = 0.05$ ، وهذه النتيجة موجودة في التقرير أيضاً حيث لدينا القيمة الاحتمالية **P-value** تساوي 0.335 وهي أكبر من مستوى الأهمية $\alpha = 0.05$ التي تعني قبول الفرضية الابتدائية H_o عند مستوى الأهمية $\alpha = 0.05$.

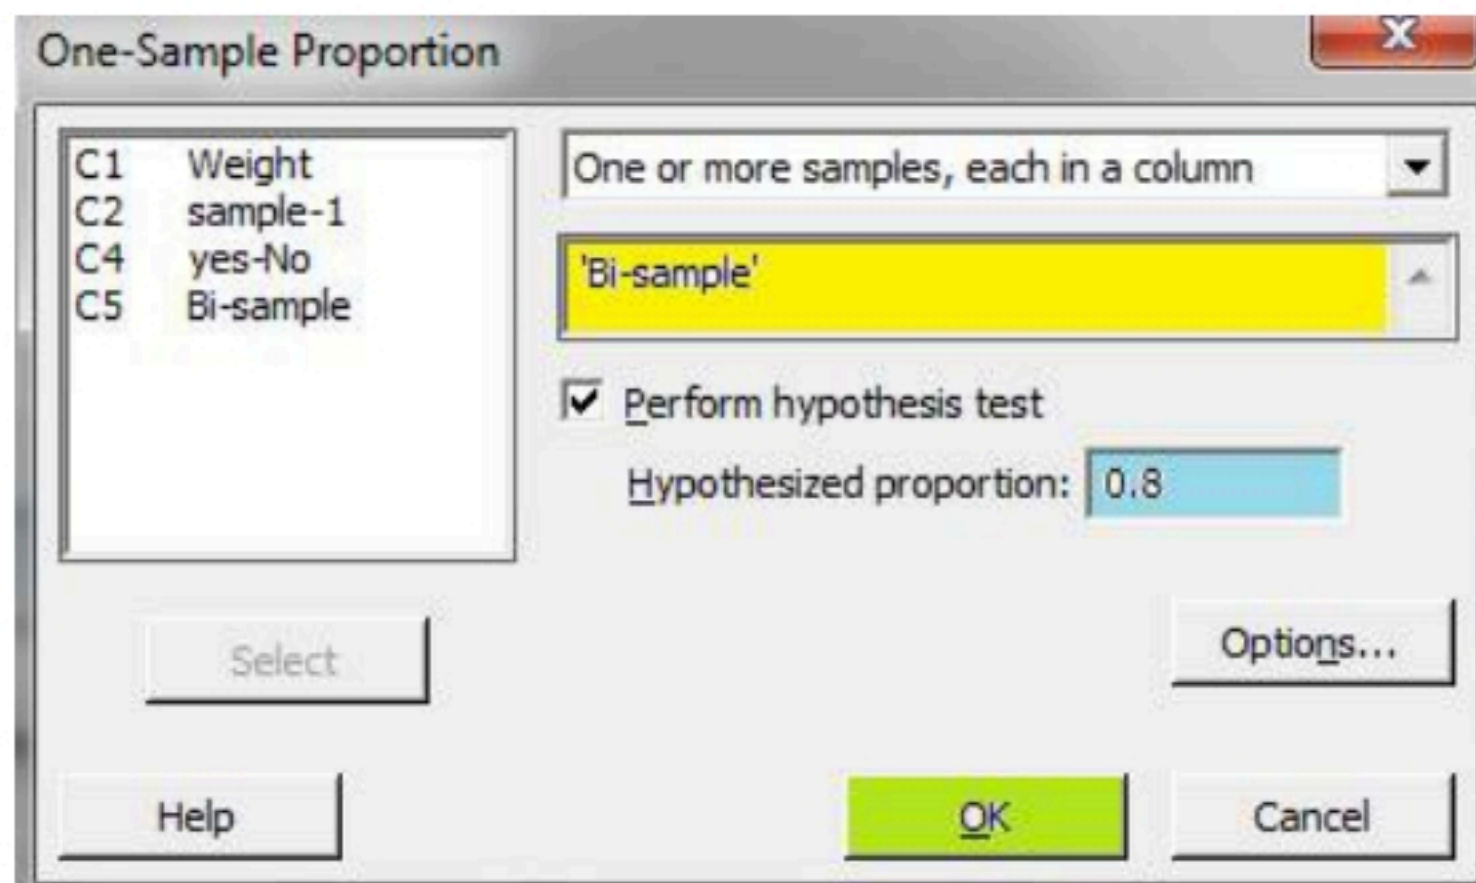
(١١, ٨, ١, ٢) ملاحظة

بأسلوب مماثل تماماً يمكننا تنفيذ الاختبارات الإحصائية الخاصة بفرق المتوسطين ونسبة التباين لمجتمعين طبيعيين.

(١١, ٨, ٢) تطبيق

بالعودة إلى التطبيق (١٠, ٤, ٢) الذي استخدم في نهاية الفصل السابق، حيث كان لدينا بيانات (تحت مسمى **Bi-sample**) تمثل عينة بحجم 81 شخصاً استطلعت آراؤهم حول مشروع تنموي، علماً أن الإجابة "موافق" مثلت بالعدد (1) في حين مثلت الإجابة "غير موافق" بالعدد (0) ، ولنختبر الفرضية الابتدائية القائلة إن احتمال أن يجيب شخص ما بعبارة "نعم" (أي للمعلمة مجتمع آراء الأشخاص p) يساوي 0.8 وذلك عند مستوى من الأهمية قدره $\alpha = 0.05$ ، أي إنه علينا اختبار الفرضية الابتدائية $H_o : p = p_o = 0.8$ مقابل الفرضية البديلة $H_A : p \neq p_o = 0.8$ وذلك عند مستوى من الأهمية قدره $\alpha = 0.05$. من أجل ذلك نتبع الخطوات الآتية:

Stat → Basic Statistics → 1-Proportion → Insert Bi-sample in free space → Activation Perform hypothesis test → Insert the value 0.8 in the space for Hypothesis proportion → OK.



يمكننا تغيير مستوى الأهمية α من أيقونة Options.

فنحصل على التقرير الآتي الذي يحتوي على 95% فترة ثقة للمعلمة p بالإضافة لنتيجة الاختبار المنشود والمُدونة في السطر الأخير من

التقرير.

Test and CI for One Proportion: Bi-sample					
Test of p = 0.8 vs p ≠ 0.8					
Variable	X	N	Sample p	95% CI	P-Value
Bi-sample	68	81	0.839506	(0.741200; 0.911681)	0.409

ومن هذا التقرير نلاحظ أنَّ القيمة الاحتمالية **P-value** تساوي 0.409 وهي أكبر من مستوى الأهمية $\alpha = 0.05$ ، ومن ثمَّ ليس أماننا إلاَّ القبول بالفرضية لابتدائية H_o عند مستوى الأهمية $\alpha = 0.05$.

(١١,٨,٢,١) ملاحظة

بأسلوب مماثل تماماً يمكننا الحصول على العروض وفترات الثقة الخاصة بفرق النسبتين $p_1 - p_2$ لمجتمعين برنوليّين.

هذا ما تيسَّر تقديمه من أجل الجزء النظري والتطبيقي لهذا الفصل

تمارين الفصل الحادي عشر

١- زعمت إحدى شركات إنتاج الملفات الكهربائية أن متوسط قيم حثية الملفات المنتجة لديها يساوي 5000 mH ميلي هنري (Henry) الهنري وحدة قياس حثية الملفات) وبانحراف معياري $\sigma = ?$ ، قمنا بسحب عينة عشوائية من إنتاج هذه الشركة بحجم n فوجدنا أن متوسط قيم حثية الملف 4982 ميلي هنري وبانحراف معياري قدره 28 ميلي هنري، فإذا افترضنا أن القيم الناتجة عن قياسات حثية الملفات تتبع التوزيع الطبيعي، فعندئذ:

أ- اختبر الفرضية الإحصائية القائلة بصحة ادعاء الشركة المنتجة عند مستوى من الأهمية قدره $\alpha = 0.01$ إذا علمت أن $n = 16$ ملفاً و $\sigma = 25$ ميلي هنري.

ب- اختبر الفرضية الإحصائية القائلة بصحة ادعاء الشركة المنتجة عند مستوى من الأهمية قدره $\alpha = 0.01$ إذا علمت أن $n = 16$ ملفاً و $s = 22$ ميلي هنري.

ج- أعد الطلب السابق / أ / من أجل $n = 81$ ، وماذا تلاحظ؟

د- اختبر الفرضية الإحصائية القائلة إن تباين قيم حثية الملفات لدى الشركة يساوي 600 عند مستوى من الأهمية قدره $\alpha = 0.05$ إذا علمت أن $n = 16$ ملفاً، و $s = 22$ ميلي هنري.

هـ- أعد الطلب السابق / د / من أجل $n = 81$ ، وماذا تلاحظ؟

٢- يدعي منتج لنوع من الدارات الإلكترونية أنه على ثقة قدرها 98% بأن أكثر من 20% من الدارات المصنعة لديه تعمل بشكل جيد بين درجتي الحرارة -15 و +70 درجة مئوية، وللتأكد من ذلك قمنا بسحب عينة حجمها n ، وأجريت عليها الدراسة المطلوبة وفقاً لادعاء المنتج، فوجدنا من بينها m دارة تعمل بشكل جيد في نطاق درجتي الحرارة المذكورة آنفاً (علماً أن $n > m$).
السؤال هو: هل تؤيد بيانات العينة صحة ادعاء المنتج إذا علمت أنه:

أ- لدينا $n = 64$ و $m = 56$ ؟

ب- لدينا $n = 289$ و $m = 253$ ؟

٣- يدعي مصنع لإنتاج أسلاك التسخين المستخدمة في المدافئ الكهربائية أن متوسط قيم مقاومة المتر الطولي لهذه الأسلاك يساوي 1.5 أوم (Ohm الأوم وحدة قياس مقاومة مرور التيار الكهربائي في سلك أو ممانعة دارة إلكترونية أو كهربائية، ويرمز لها بـ Ω) بانحراف قدره σ أوم، وللتأكد من مدى صحة هذا الادعاء قمنا بأخذ عينة مكونة من n قطعة طول كل منها يساوي متراً واحداً، فوجدنا أن متوسط المقاومة لهذه القطع يساوي 1.6 أوم بانحراف معياري قدره s أوم، فإذا علمت أن قيم المقاومة للمتر الطولي لأسلاك التسخين تتوزع طبيعياً، والمطلوب ما يلي:

أ- إذا كان $\sigma = 0.2$ أوم، فعندئذ اختبر الفرضية القائلة إن متوسط قيمة المقاومة للمتر الطولي لهذه الأسلاك أكبر من 1.5 أوم، وذلك عند مستوى من الأهمية قدره $\alpha = 0.05$.

ب- إذا كان σ مجهولاً و $s = 1$ أوم و $n = 49$ ، فعندئذ اختبر الفرضية القائلة إن متوسط قيمة المقاومة للمتر الطولي لهذه الأسلاك أكبر من 15 أوم وذلك عند مستوى من الأهمية قدره $\alpha = 0.05$.

ج- أعد الطلب السابق إذا كان $n = 256$.

د- إذا كان $n = 36$ و $s = 1.5$ ، عندئذ اختبر الفرضية القائلة إن قيم المقاومة للمتر الطولي للأسلاك له انحراف معياري قدره 1.25 أوم، وذلك عند مستوى من الأهمية $\alpha = 0.01$.

٤- يدعي مصنع لإنتاج كبسولات لنوع من المضادات الحيوية أن هذه الكبسولات تحوي 500 mg من المادة الفعالة بانحراف معياري قدره 5 mg وذلك عند مستوى من الثقة قدره 98% ، وللتأكد من صحة ادعاء المصنع قمنا بسحب عينة حجمها n فوجدنا أن متوسط وزن المادة الفعالة في كبسولات العينة يساوي 490 mg بانحراف معياري قدره 4 mg ، فعندئذ:

- أ- إذا كان حجم العينة $n = 25$ كبسولة، فما هو ردك على ادعاء المصنع مستخدماً اختبار الفرضيات؟
 ب- اختبر الفرضية القائلة إن متوسط وزن المادة الفعالة في الكبسولات أقل من 500 mg عند مستوى من الأهمية $\alpha = 0.05$ ؟
 ج- إذا كان حجم العينة $n = 81$ كبسولة، ووجدنا أن 70 كبسولة منها مُحَقَّقة للمواصفات المقدمة من قبل المصنع، فعندئذ اختبر الفرضية القائلة إن نسب الكبسولات المنتجة والمُحَقَّقة للمواصفات المقدمة من قبل المصنع يساوي 88% وذلك عند مستوى من الأهمية قدره $\alpha = 0.001$.

٥- ادعت وزارة البيئة في بلد ما أنها على ثقة قدرها 95% بأنه أكثر من 85% من المصانع الموجودة في البلد تُحَقِّق معايير مكافحة تلوث البيئة، ولكن أنصار المحافظة على البيئة أرادوا التَحَقُّق من صحة هذا الادعاء، فقاموا بدراسة ميدانية للكشف عن التلوث (وفقاً لمعايير متفق عليها) في 64 موقعاً اختيرت بشكل عشوائي، فوجدوا أن 56 موقعاً يُحَقِّق معايير مكافحة التلوث، والمطلوب:

- أ- ما هو رد أنصار المحافظة على البيئة إذا كان اختبارهم مبنياً على مستوى الأهمية $\alpha = 0.05$ ؟
 ب- ما هو حجم العينة n بحيث إنه عند مستوى من الأهمية $\alpha = 0.01$ يكون رد أنصار المحافظين على البيئة إيجابياً إذا كانت النسبة المستحصل عليها من العينة هي 80%؟
 ج- إذا كان $n = 64$ موقعاً، ووجد أن 53 موقعاً تُحَقِّق معايير مكافحة التلوث للبيئة، فعندئذ أي مستوى من الأهمية يكون فيه رد أنصار المحافظين على البيئة إيجابياً؟

٦- في مصنع لإنتاج القضبان الحديدية يوجد خطان لإنتاج القضبان ذات القطر 6 مم وطول 6 م، ويعملان بشكل مستقل كل منهما عن الآخر، فقمنا بسحب عينة X_{36} و Y_{20} من إنتاج الخط الأول والثاني على الترتيب، فوجدنا أن متوسط قطر القضبان للعينة X_{36} و Y_{20} هي 6.15 مم و 5.95 مم على الترتيب وبانحراف معياري على الترتيب هو 0.25 مم و 0.35 مم على الترتيب أيضاً. الآن، وبفرض أن قيم قياسات أقطار القضبان تخضع للتوزيع الطبيعي، فعندئذ اختبر الفرضية الإحصائية القائلة:

- أ- إن متوسط أقطار القضبان المنتجة من الخطين متساوية عند مستوى من الأهمية قدره $\alpha = 0.05$.
 ب- إن تباين قيم الأقطار للقضبان المنتجة من الخطين متساوية عند مستوى من الأهمية قدره $\alpha = 0.01$.

٧- قام رجلان بالرمي على هدف واحد، وبشكل مستقل كل منهما عن الآخر، وبحيث لا يعلم أي منهما شيئاً عن إصابته للهدف أثناء عملية الرمي، فإذا قام الأول بإطلاق 180 رمية على الهدف تُحَقِّق منها 170 إصابة للهدف، في حين أطلق الثاني 150 رمية على الهدف تُحَقِّق منها 143 إصابة للهدف، فهل يمكننا الادعاء أن للرجلين الكفاءة نفسها في الرمي عند مستوى من الأهمية $\alpha = 0.05$ ، وهل يبقى القرار نفسه من أجل $\alpha = 0.45$ ؟

٨- لدى رصد عدد الحوادث المرورية على طريق عام معين وخلال الفترة من الساعة 14 إلى 15 (2 وحتى 3 بعد الظهر) وجدت البيانات الآتية لـ 16 يوماً متفرقة اختيرت عشوائياً من عام مُحَدَّد:

اليوم	1	2	3	4	5	6	7	8
X عدد الحوادث	3	0	5	4	1	0	0	2
اليوم	9	10	11	12	13	14	15	16
X عدد الحوادث	1	1	2	0	3	0	0	1

والمطلوب اختبار الفرضية القائلة إنَّ عدد الحوادث وفقاً لما ذكر يخضع للتوزيع البواسوني عند مستوى من الأهمية $\alpha = 0.01$.

٩- أخذت عينة بحجم 12 عداء من مجتمع المتقدمين لسباق المارثون فوجد زمن وصولهم للهدف المنشود معطى كما في الجدول الآتي:

رقم العداء	1	2	3	4	5	6
X الزمن المستغرق	2:42	2:50	2:55	2:40	3:20	2:54
رقم العداء	7	8	9	10	11	12
X الزمن المستغرق	3:15	3:00	3:15	3:50	3:10	3:00

والمطلوب اختبار الفرضية القائلة إنَّ زمن وصول المتسابقين للهدف يخضع للتوزيع الأسّي وذلك عند مستوى من الأهمية $\alpha = 0.05$.

١٠- في مركز لاختبار العينات للبضائع الصناعية والزراعية يوجد ثلاثة معامل مخبرية L_1 ، L_2 و L_3 تقوم بهذه الاختبارات، ولدى معاينة عينة من نتائج المخبر L_1 ، L_2 و L_3 بحجم $n_1 = 49$ ، $n_2 = 64$ و $n_3 = 81$ على الترتيب، لاحظنا أنه يوجد لدى بعض هذه المعامل المخبرية نتائج غير صحيحة وعددها معطى كما في الجدول الآتي:

رقم العداء	L_1	L_2	L_3
نتائج صحيحة	67	41	89
رقم العداء	7	8	9
نتائج خاطئة	4	3	5

والمطلوب اختبار الفرضية القائلة إنَّ نسب النتائج الصحيحة المقدمة من قبل هذه المعامل المخبرية متساوية عند مستوى من الأهمية قدره $\alpha = 0.05$.

١١- لدى أخذ عينة بحجم 86 قضيب حديدي بطول متر واحد وقطر 10 مم من إنتاج مصنع للحديد والصلب وإخضاع هذه العينة لفحص قوة الشد مقدرة بـ 10 ميلي بار، وكانت نتائج تحديد نسبة الكربون الموجودة في معدن القضيب مقدرة بالنسبة المئوية كما في الجدول الآتي:

		قوة الشد						المجموع
		60→64	64→68	68→72	72→76	76→80	80→84	
نسبة الكربون	0.35→0.37	1	1	0	0	0	0	
	0.37→0.39	1	3	2	1	0	0	
	0.39→0.41	2	3	7	3	0	0	
	0.41→0.43	1	4	11	12	1	0	
	0.43→0.45	1	1	3	7	5	0	
	0.45→0.47	0	0	4	3	5	1	
	0.47→0.49	0	0	0	0	3	0	
Total								

والمطلوب اختبار الفرضية القائلة إنَّ قوة تحمل القضيب للشد مستقلة عن نسبة الكربون الموجودة في معدن القضيب وذلك عند مستوى الأهمية $\alpha = 0.01$.

١٢- اختبرت عيشتان عشوائيتان من طلبة قسم الكيمياء في جامعتين X و Y للقيام بتنفيذ تجربة معينة وتحت الشروط نفسها، وبحيث إن المهارات الفردية تقوم بدور فعال في تحقيق النتائج المرجوة من هذه التجربة، فإذا علمنا أن كل طالب يقوم بإجراء التجربة بشكل مستقل عن الآخرين وأن حجم العينة الأولى (من الجامعة X) يساوي n ، وحجم العينة الثانية (من الجامعة Y) يساوي m ، وبفرض أن التجربة تحققت بشكل إيجابي من قبل n_1 و m_1 طالب في العينة الأولى والثانية على الترتيب. عندئذ اختبر الفرضية القائلة بتساوي الكفاءة لدى طلبة الجامعتين عند مستوى من الأهمية قدره α ، وذلك من أجل الحالات الآتية:

أ- لدينا $n = 36$ ، $n_1 = 25$ ، $m = 49$ ، $m_1 = 39$ و $\alpha = 0.05$.

ب- لدينا $n = 360$ ، $n_1 = 250$ ، $m = 490$ ، $m_1 = 390$ و $\alpha = 0.05$.

ج- لدينا $n = 36$ ، $n_1 = 25$ ، $m = 49$ ، $m_1 = 39$ و $\alpha = 0.01$.

١٣- في مصنع لإنتاج المصابيح الكهربائية يوجد خمسة خطوط للإنتاج L_1 ، L_2 ، L_3 ، L_4 و L_5 ويعمل كل منها بشكل مستقل عن الخطوط الأخرى، وأن كل خط ينتج ثلاثة أنواع من المصابيح ذات الاستطاعة 60 و 90 و 150 واط. الآن إذا افترضنا أن عملية الإنتاج لهذه الخطوط تتبع توزيعاً طبيعياً بمتوسط μ_1 ، μ_2 ، μ_3 ، μ_4 و μ_5 وبانحراف معياري σ_1 ، σ_2 ، σ_3 ، σ_4 و σ_5 على الترتيب علماً أن $\sigma_1 = \sigma_2 = \sigma_3 = \sigma_4 = \sigma_5$ ، وقمنا بسحب عينات عشوائية من إنتاج هذه الخطوط بحجم:

$$n_1 = 255 \text{ \& } n_2 = 255 \text{ \& } n_3 = 242 \text{ \& } n_4 = 245 \text{ \& } n_5 = 248$$

على الترتيب، وكانت نتائج دراسة هذه العينات كما في الجدول الآتي:

		الاستطاعة			المجموع
		60W	90W	150 W	
الخط	L_1	87	78	90	
	L_2	83	81	91	
	L_3	79	79	84	
	L_4	81	82	82	
	L_5	80	80	88	
Total					

عندئذ اختبر الفرضية القائلة بتساوي متوسطات الإنتاج لهذه الخطوط الخمسة عند مستوى الأهمية $\alpha = 0.05$.

١٤- في مستشفى يوجد خمس عيادات B_1 ، B_2 ، B_3 ، B_4 و B_5 تعمل كل منها بشكل مستقل عن الأخرى، قمنا بسحب عينات عشوائية من سجلات المرضى الذين زاروا هذه العيادات بحجم $n_1 = 85$ ، $n_2 = 77$ ، $n_3 = 95$ ، $n_4 = 118$ و $n_5 = 95$ على الترتيب فوجد أن عدد المرضى الذين تماثلوا للشفاء في هذه العيادات مقدّم كما في الجدول الآتي:

		العيادة					المجموع
		1	2	3	4	5	
الحالة	تماثل للشفاء	82	75	93	105	88	
	لم يتماثل للشفاء	3	2	2	13	7	
Total							

والمطلوب اختبار الفرضية القائلة بتساوي نسب المرضى الذين تماثلوا للشفاء في هذه العيادات الخمس وذلك عند مستوى الأهمية $\alpha = 0.01$.

الفصل الثاني عشر

المتسلسلات الزمنية

TIME SERIES

(١٢, ١) مفاهيم أولية في المتسلسلات الزمنية

Initial Concepts in Time Series

لقد قدّمنا في الفصول الثلاث الأولى من هذا الكتاب دراسات أولية متنوعة حول البيانات وتحليلها، وذكرنا في فصل الارتباط وتحليل الانحدار أنه من الممكن أن يكون لدينا بيانات متزاوجة $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ فيها البيانات x_1, x_2, \dots, x_n و y_1, y_2, \dots, y_n فهي قيم مقيسه عند هذه اللحظات الزمنية على الترتيب (وسنرمز لها فيما بعد بـ t_1, t_2, \dots, t_n)، وأما القيم y_1, y_2, \dots, y_n فهي قيم مقيسه عند هذه اللحظات الزمنية على الترتيب (وسنرمز لها بـ $x_{t_1}, x_{t_2}, \dots, x_{t_n}$). أكثر من ذلك، فقد تكون لدينا عدّة قيم مقيسه $x_{1i}, x_{2i}, \dots, x_{mi}$ موافقة للحظة زمنية t_i من أجل أي $i \in \mathbb{N}_n$ ، والأمثلة البسيطة الآتية توضّح لنا بعضاً منها:

- ١ - القيمة المسجّلة كل ساعة لأسعار أسهم شركة ما في البورصة.
- ٢ - كمية الهطل المطري الشهري على منطقة محدّدة.
- ٣ - القياسات المأخوذة لدرجة الحرارة والضغط لمريض كل ساعتين في مستشفى.
- ٤ - قيمة المبيعات اليومية من اللحوم، الخضراوات، الملابس والأجهزة الكهربائية في سوق تجاري.
- ٥ - عدد القتلى في معارك لبلد ما مع مرور الزمن.
- ٦ - عدد حوادث الطيران المدني في عام 2014.

فلاحظ من الأمثلة السابقة أنّ البيانات التي يمكن أن نحصل عليها مرتبطة بالزمن. إنّ دراسة وتحليل هذا النوع من البيانات يتطلب منهجاً خاصاً في كثير من جوانبه، ولذلك تُصنّف هذه البيانات في مُسمّى خاص بها يُدعى **المتسلسلات الزمنية** والذي يقدّمه لنا التعريف الآتي.

(١٢, ١, ١) تعريف (المتسلسلة الزمنية Time Series)

المتسلسلة زمنية هي مجموعة من المشاهدات (أو الملاحظات لأشياء معرّفة جيداً) تمّ الحصول عليها من خلال القياسات المتكرّرة على مرّ الزمن. بعبارة موجزة: المتسلسلة الزمنية هي مجموعة بيانات مُرتّبة زمنياً.

الآن وبناءً على هذا التعريف، وبإمعان النظر في الأمثلة المذكورة سابقاً فإنّنا نلاحظ ما يلي:

- ١ - بعد الأخذ بالحسبان أنّ الزمن جزء لا يتجزأ من مفهوم المتسلسلة الزمنية، فإنّ المتسلسلة الزمنية يمكن أن يكون لها أكثر من بُعد واحد وذلك بحسب عدد القيم المأخوذة عند كل لحظة زمنية، فعلى سبيل المثال
- أ - نجد المثالين الأول والثاني السابقين يقدّمان لنا متسلسلتين زمنتين لهما بُعد يساوي الواحد، وفي دراستنا المقبلة لن نقدّم إلّا هذا النوع من المتسلسلات الزمنية.

ب- يقدم لنا المثال الثالث متسلسلة زمنية بعدها يساوي 2، وكذلك المثال الرابع يقدم لنا متسلسلة زمنية بعدها يساوي 4، وهذه الأنواع من المتسلسلات الزمنية ستكون خارج إطار دراستنا في هذا الكتاب.

٢- من الممكن أن تؤخذ القياسات على فترات زمنية (تُدعى فجوات زمنية **Lags**) غير منتظمة (أي على فترات زمنية غير متساوية **الطول**)، والمثال الخامس يقدم لنا متسلسلة زمنية من هذا النوع؛ وذلك لأن المراكز التي تحصل لبلد ما لا تحدث على فترات زمنية متساوية الطول في الحالة العامة، وهذا النوع من المتسلسلات الزمنية لن نتناوله في دراستنا المقبلة أيضاً. أي إننا في دراستنا المقبلة سندرس متسلسلات زمنية قيمها تحدث على فترات زمنية متساوية الطول (لها فجوات زمنية متساوية الطول).

٣- البيانات التي يتم جمعها مرة واحدة فقط ليست متسلسلة زمنية، ومن ثم المثال السادس لا يقدم لنا متسلسلة زمنية.

في الواقع إن دراسة المتسلسلات الزمنية يمكن أن تقدم على مستويات عديدة من المعرفة العلمية، فيمكن أن تقدم بشكلها التقليدي البسيط، أو تقدم بعروض رياضية متقدمة مبنية على دراسات متقدمة في نظرية الطوريات العشوائية ونظرية تحليل الانحدار، وقد تقدم في مستوى وسط بين المستويين السابقين. في هذا الفصل سوف نعتمد على المستوى الأول ونقدم المعلومات بشكلها التقليدي البسيط من أجل التعريف بهذا العلم وفهم المصطلحات الأساسية التي تتعامل معها. علماً أننا سنعتمد وبشكل أساس على المراجع [12]، [33] و [67] في تقديم هذا الفصل، ونوجه القارئ إلى المراجع الآتية (الموجودة في فهرس مراجع هذا الكتاب) إذا رغب في معرفة المزيد حول هذا النوع من الدراسات العشوائية التطبيقية [9]، [11]، [21]، [25]، [32]، [34] و [48].

من المفاهيم الضرورية في إطار دراسة المتسلسلات الزمنية ما يُعرف باسم **الطوري العشوائي** الذي سنقدم تعريفه على النحو الآتي.

(١٢, ١, ٢) تعريف (الطوري العشوائي الحقيقي Real Random Process)

ليكن $[\Omega, \mathcal{A}, P]$ فضاءً احتمالياً، و $\mathbb{R} \supseteq T$ مجموعة غير خالية، ولنأخذ $X : T \times \Omega \rightarrow \mathbb{R}$ بحيث $(t, \omega) \mapsto X(t, \omega)$ تطبيقاً قيوساً بالنسبة إلى \mathcal{A} و \mathbb{R} من أجل كل قيمة $T \ni t$ مثبتة، فعندئذ أسرة كل المتغيرات العشوائية $\{X(t, \cdot) ; t \in T\}$ تُدعى **طورياً عشوائياً حقيقياً** (أو **طورياً عشوائياً Random Process** حيث سنقتصر دراستنا هذه على الطوريات العشوائية الحقيقية فقط).

(١٢, ١, ٢, ١) ملاحظات

١- يمكن تعريف الطوري العشوائي بطريقة أخرى أيضاً وذلك من خلال أخذ $\mathbb{R} \supseteq T$ مجموعة غير خالية، وكذلك أخذ $X_t : \Omega \rightarrow \mathbb{R}$ بحيث $\omega \mapsto X_t(\omega)$ تطبيقاً قيوساً بالنسبة إلى \mathcal{A} و \mathbb{R} من أجل كل $T \ni t$ مثبتة، فعندئذ تُدعى أسرة كل المتغيرات العشوائية $\{X_t ; t \in T\}$ **طورياً عشوائياً** (ويُكتب بالشكل الآتي أيضاً $\{X_t\}_{t \in T}$).

٢- من أجل أي حدث ابتدائي $\Omega \ni \omega$ مثبت يكون $X_\bullet(\omega)$ دالة حقيقية على T ، وفي هذه الحالة يُطلق على الدالة $X_t(\omega)$ (وكذلك رسمها البياني كدالة بـ t) اسم **مسار Trajectory** للطوري العشوائي $\{X_t ; t \in T\}$ ، ومن ثم يكون للطوري العشوائي $\{X_t ; t \in T\}$ مسارات عددها يساوي قدرة فضاء الحوادث الابتدائية Ω .

٣- في كثير من الدراسات يتم التعامل مع المجموعة T (والتي تُدعى **مجموعة معالم الطوري العشوائي**) على أنها فترة زمنية، ولذلك ينظر إلى القيم $T \ni t$ على أنها لحظات زمنية، وسنعتمد هذا المفهوم في دراستنا للمتسلسلات الزمنية.

٤- إذا كانت مجموعة المعالم $T = \mathbb{N}_n$ مع $\mathbb{N} \ni n$ مثبتة، فعندئذ يتحدث المرء عن متتالية منتهية من المتغيرات العشوائية أو متجه عشوائي حقيقي.

٥- إذا كانت مجموعة المعالم T قابلة للعد على الأكثر، فعندئذ يتحدث المرء عن متتالية من المتغيرات العشوائية (وفي مثل هذه الحالة غالباً ما تؤخذ $T \supseteq \mathbb{N}^0$).

٦- لكل متسلسلة زمنية يوجد طور عشوائي $\{X_t; t \in T\}$ يولدها، ولذلك فمن أجل عينة محدّدة من مسار هذه المتسلسلة الزمنية سنرمز لقيمة هذا الطوري العشوائي (قيمة إحدى مشاهداته) عند لحظة زمنية $t \in T$ بالرمز x_t .

٧- بفرض أنّه لدينا $(t_1, x_{t_1}), (t_2, x_{t_2}), \dots, (t_\tau, x_{t_\tau})$ عينة حجمها يساوي τ مأخوذة من مسار متسلسلة زمنية، وننوّه هنا إلى أنّ استخدام الحرف τ دارج في مجال دراسة المتسلسلات الزمنية للتعبير عن حجم البيانات المأخوذة من مسار متسلسلة زمنية، ولكن نستخدم الرموز المألوفة سابقاً n أو m بين الحين والآخر أيضاً.

٨- بما أنّ دراستنا المقبلة مركّزة على المتسلسلات الزمنية التي قيمها تحدث على فترات زمنية متساوية الطول، فإنّنا سنقوم (وفي كثير من الحالات) بإلباس اللحظة الزمنية بدليلها على سبيل التبسيط. أي سنكتب 1 عوضاً عن t_1 وكذلك 2 عوضاً عن t_2 وهكذا دواليك حتى اللحظة الزمنية الأخيرة t_τ سنكتبها τ ، ومن ثمّ يصبح لدينا العرض الآتي للملاحظات السابقة $(1, x_1), (2, x_2), \dots, (\tau, x_\tau)$ (هذا على سبيل التبسيط فقط).

٩- لقد استخدمنا هنا الرمز τ لكي نشير به إلى أنّ القيمة x_τ وهي آخر قيمة تمّ الحصول عليها، ومن ثمّ فهي تشير إلى القيمة التي حصلنا عليها في الوقت الحاضر، وما يأتي بعدها من قيم مثل $x_{\tau+1}, x_{\tau+2}, \dots$ إنّما هي قيم متنبأ بها للمستقبل، وأما القيم السابقة لـ x_τ مثل $x_{\tau-1}, x_{\tau-2}, \dots, x_2, x_1$ فهي قيم من ماضي المتسلسلة الزمنية وأقدمها x_1 التي تمثّل أو قيمة تمّ الحصول عليها في العينة.

الآن، ومن أجل دراسة متسلسلة زمنية مُعطاة نقوم عادة بتجزئة هذه الدراسة على مراحل عدّة، وأول هذه المراحل هي تقديم ما يُعرف باسم بصمة المتسلسلة الزمنية (أو العرض الانتشاري لمتسلسلة زمنية)، حيث يمكن لهذا العرض أن يقدّم لنا تصوراً أولياً حول مسار وسلوك المتسلسلة الزمنية. إنّ هذا المفهوم يقدّمه لنا التعريف الآتي.

(١٢, ١, ٣) تعريف (بصمة متسلسلة زمنية Imprint of Time Series)

لتكن x_1, x_2, \dots, x_τ مشاهدات مأخوذة من مسار متسلسلة زمنية، فلو قمنا بالتمثيل النقطي لهذه المشاهدات على لوحة الانتشار كما سبق وقدمناه في فصل الارتباط والانحدار، ومن ثمّ الوصل بين هذه النقاط على التتالي بقطع مستقيمة، ومع الافتراض أنّ المحور الأفقي هو محور الزمن T حيث تدوّن عليه اللحظات الزمنية، في حين أنّ المحور الرأسي هو محور القيم وتعيّن عليه القيم x_1, x_2, \dots, x_τ ، فعندئذ يُعرف الشكل البياني الناتج باسم بصمة المتسلسلة الزمنية.


(١٢, ١, ٣, ١) أمثلة

١- لتكن لدينا المشاهدات الآتية التي تمثّل عدد الإصابات غير المميتة في حوادث مرورية في مدينة الرياض خلال العامين 1423 و1424هـ.

الجدول (١٢, ١)

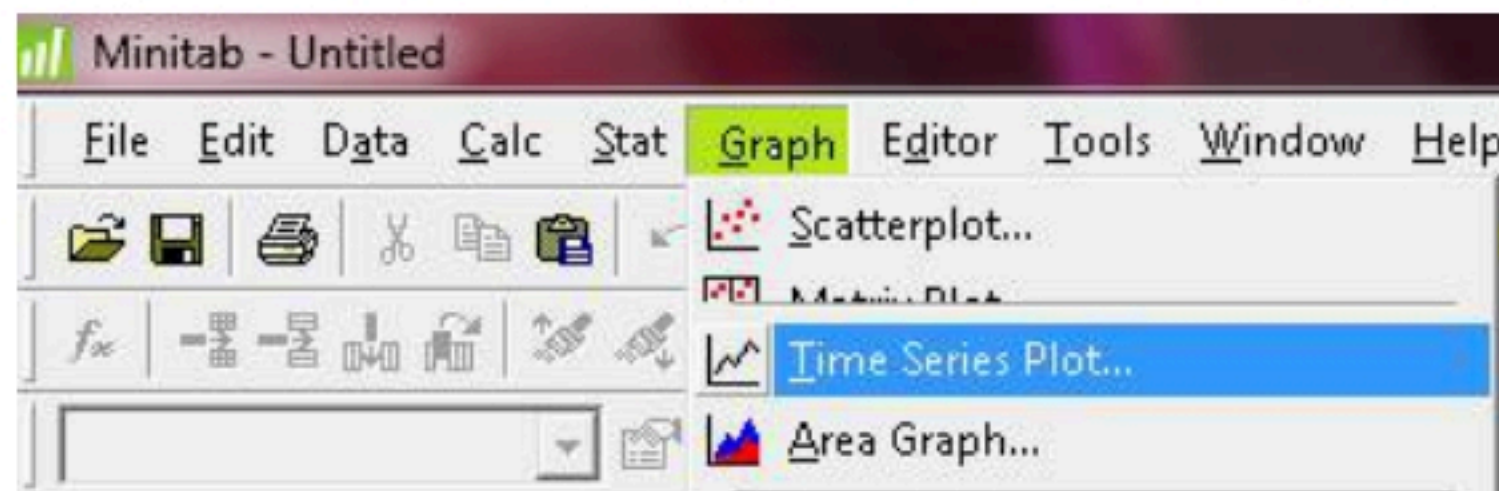
العام هـ	الشهر	1	2	3	4	5	6
1423	عدد الإصابات	151	148	125	149	163	148
1424	عدد الإصابات	144	181	124	122	136	112
العام هـ	الشهر	7	8	9	10	11	12
1423	عدد الإصابات	171	166	119	153	159	141
1424	عدد الإصابات	116	148	116	109	143	95

فَعِنْدَئِذٍ سَيَكُونُ لِبَصْمَةِ هَذِهِ الْمَتَسَلْسَلَةِ الزَّمْنِيَةِ الْعَرَضِ الْبَيَانِي الْآتِي:

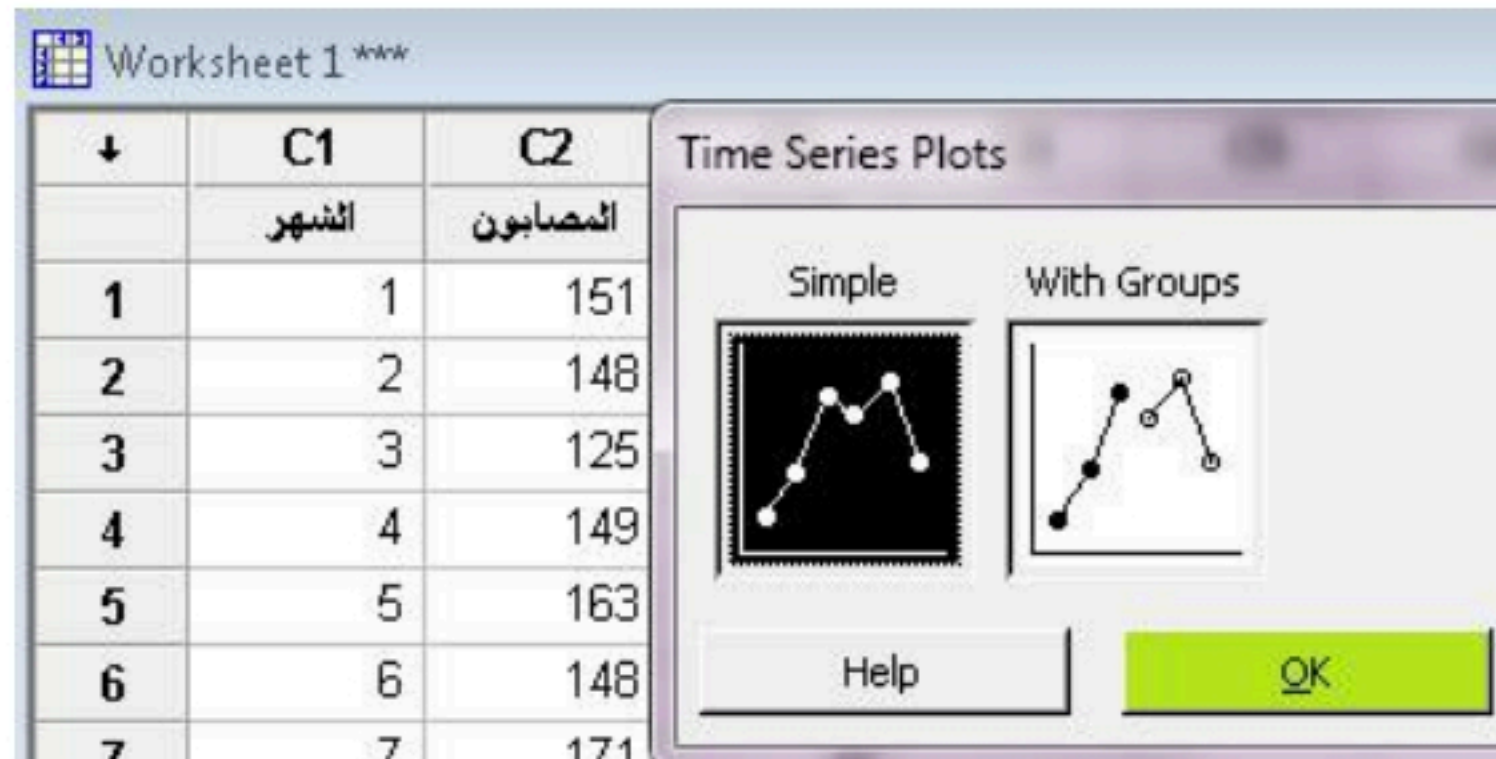


بِالطَّبْعِ مِنَ الْمُمْكِنِ الْحَصُولُ عَلَى بَصْمَةِ الْمَتَسَلْسَلَةِ الزَّمْنِيَةِ بِاسْتِخْدَامِ بَرْنَامِجِ Minitab بِاسْتِخْدَامِ الْخَطَوَاتِ الْآتِيَةِ:

Graph → **Time Series** → **Simple** → **OK** → **Insert (المصابون)** → **OK**



وَمِنْ ثَمَّ



وَبَعْدَ ذَلِكَ نَتَّبِعُ الْخَطْوَةَ التَّالِيَةَ فَنَحْصِلُ عَلَى الشَّكْلِ السَّابِقِ (١, ١٢).




٢- لتكن لدينا المشاهدات الآتية التي تمثل قيم المبيعات الشهرية (مقدرة بـ 10000 وحدة نقدية) في متجر للملابس خلال خمسة عشر شهراً متتالياً.

الجدول (١٢, ٢)

الشهر t	1	2	3	4	5	6	7	8
قيم المبيعات x_t	22	30	25	37	32	65	35	43
الشهر t	9	10	11	12	13	14	15	
قيم المبيعات x_t	38	77	40	45	42	50	45	

فعندئذ سيكون لبصمة هذه المتسلسلة الزمنية العرض البياني الآتي:




الشكل (١٢, ٢)

٣- لتكن لدينا المشاهدات الآتية التي تمثل كمية الاستهلاك الشهري للكهرباء لإحدى الشقق السكنية خلال ثلاثة أعوام متتالية (مقدرة بـ الكيلو واط الساعي Kw/S).

الجدول (١٢, ٣)

تاريخ الفاتورة	كمية الاستهلاك	تاريخ الفاتورة	كمية الاستهلاك	تاريخ الفاتورة	كمية الاستهلاك
1432/01	700	1433/01	850	1434/01	730
1432/02	555	1433/02	655	1434/02	455
1432/03	780	1433/03	805	1434/03	885
1432/04	1080	1433/04	1180	1434/04	1380
1432/05	1855	1433/05	1750	1434/05	2155
1432/06	2855	1433/06	2705	1434/06	2855
1432/07	2585	1433/07	2475	1434/07	2385
1432/08	1750	1433/08	1930	1434/08	2735
1432/09	1445	1433/09	1260	1434/09	1065
1432/10	560	1433/10	740	1434/10	550
1432/11	670	1433/11	800	1434/11	910
1432/12	1005	1433/12	950	1434/12	1085

فعدنئذ سيكون لبصمة هذه المتسلسلة الزمنية العرض البياني الآتي:




الشكل (١٢، ٣)

٤- لتكن لدينا المشاهدات الآتية التي تمثل متوسط كمية الهطل المطري السنوي على مدينة (حمص في سوريا) في بلاد الشام خلال الفترة 1950-2004 (مقدرة بالمليمتر على المتر المربع mm/m^2).

الجدول (١٢، ٤)

كمية الهطول المطري مقدرة بالمليمتر على المتر المربع mm/m^2									
السنة	الكمية	السنة	الكمية	السنة	الكمية	السنة	الكمية	السنة	الكمية
1950	630	1961	420.5	1972	351.2	1983	455.3	1994	434
1951	566	1962	419.1	1973	346.2	1984	466.1	1995	216.7
1952	421.2	1963	552.9	1974	387	1985	249.1	1996	357.3
1953	654.5	1964	503.6	1975	429	1986	328.1	1997	468.4
1954	589.7	1965	506.4	1976	378.9	1987	450.3	1998	380.5
1955	333.1	1966	362.1	1977	375.2	1988	564.1	1999	143
1956	532	1967	758.9	1978	405.8	1989	205.5	2000	330
1957	395.2	1968	605.9	1979	452.2	1990	204.2	2001	388.1
1958	230.6	1969	578.6	1980	487.9	1991	446.9	2002	486.2
1959	314.8	1970	360.6	1981	474.6	1992	572	2003	672
1960	190	1971	556.5	1982	424.9	1993	289.7	2004	510.5


فعدنئذ يكون لبصمة هذه المتسلسلة الزمنية العرض البياني الآتي:



الشكل (١٢، ٤)

٥- لتكن لدينا المتسلسلة الزمنية الآتية (سنكتفي بعرض بصفة هذه المتسلسلة الزمنية بسبب كبر حجم العينة $\tau = 205$ ، وهي متسلسلة

زمنية افتراضية):



الشكل (٥، ١٢)

الآن لو أمعنا النظر في العروض البيانية للمتسلسلات الزمنية السابقة، فإننا سنلاحظ ما يلي:

١- لكل متسلسلة زمنية يوجد منحى يرسم توجّهاً على المدى البعيد للزمن. إنَّ هذا المنحى يُدعى **الاتجاه العام** Trend للمتسلسلة الزمنية، فعلى سبيل المثال نجد الاتجاه العام للمتسلسلتين الزميتين في المثالين ١ / و ٤ / هابطاً في حين أنَّ الاتجاه العام للمتسلسلة الزمنية في المثال ٢ / صاعداً، وأخيراً نلاحظ أنَّ الاتجاه العام للمتسلسلتين الزميتين في المثالين ٣ / و ٥ / يكاد يكون ثابتاً (أفقاً).

٢- يوجد في مسار معظم المتسلسلات الزمنية السابقة اهتزازات ذات أنماط مختلفة، فمنها:

- أ- اهتزازات توافقية أو شبيهة بالاهتزازات التوافقية، كما يُلاحظ في الأشكال (١، ١٢)، (٣، ١٢) و (٥، ١٢).
- ب- اهتزازات متسعة المطال تحصل فجأةً وعند فترات محدّدة، كما يُلاحظ في الشكل (٢، ١٢).
- ج- اهتزازات صغيرة في مسار الاهتزازات السابقة، ولكنها قد تكون غير منتظمة في ترددها ومطالها، كما يُلاحظ في الشكل (٤، ١٢)، أو منتظمة في ترددها ومطالها، كما يُلاحظ في الشكل (٥، ١٢).

إنَّ هذه الملاحظات توحي لنا أنَّ ثمة تركيباً مُعيّناً لمكوّنات ما أدّت إلى هذا البناء للمتسلسلات الزمنية، بمعنى أنَّ بيانات المتسلسلات الزمنية هي في الواقع تفاعل لمجموعة مؤثّرات يُمكنُ البحث في دراسة سلوك كلّ منها وفقاً للكائن الرياضي الذي يُمثّلها. إنَّ هذا التأويل يدفعنا إلى معرفة البنى الرياضية المكوّنة لنموذج المتسلسلة الزمنية، وهذا ما ستقدّمه لنا الفقرة الآتية.

(٤، ١، ١٢) مُركّبات المتسلسلات الزمنية Components of Time Series


بناءً على ما سبق، فقد اقترح تجزئة النموذج الرياضي المُمثّل للمتسلسلة الزمنية إلى أربع مركّبات هي:

١- **مُركّبة الاتجاه العام** Trend Component، وسنرمز لها بـ $m(t)$ وهي دالة بالزمن t ، وهذه المركّبة تصف التوجّه العام للمتسلسلة الزمنية على المدى البعيد للزمن.

٢- **المُركّبة الموسميّة** Seasonal Component، وفي وصف هذه المركّبة يوجد توجّهان:

أ- بعض المراجع (ومنها [33]) تصفها على أنَّها اهتزازات رتيبة Systematic Vibrations تحصل في مسار المتسلسلة الزمنية، ولكن هذه الاهتزازات تحصل في مواسم مُحدّدة، كأن تظهر كل ساعة، أو كل خمس ساعات، أو كل شهر أو كل ربع سنة، أو... وهذه

القيم الأخيرة (ساعة، خمس ساعات، شهر، ربع سنة أو...) تُدعى **طول الفترة الموسمية** (انظر الشكل الآتي)، ولكي نميِّزها عن التفسير الآتي في الفقرة /ب/ سندعوها **المركبة الموسمية الصافية** ويُرمز لها بـ $s(t)$ ، وهي دالة بالزمن t .



الشكل (٦، ١٢)

ب- معظم البرامج الإحصائية وكذلك كثير من المراجع تصف **المركبة الموسمية** على أنها تلك **المركبة** التي تشتمل على الخاصية السابقة /أ/ بالإضافة إلى التغيرات (أو **الاهتزازات**) الرتيبة في مسار المتسلسلة الزمنية التي ليس لها انتظام موسمي، وهذه الاهتزازات الأخيرة تُمثل في الواقع اهتزازات ذات نمط توافقي Harmonic Model شبيهة باهتزازات دالة الجيب \sin وجيب التمام (التجيب) \cos ، ولكي نميِّز هذه الاهتزازات عن التوصيف السابق /أ/ سنرمز لها بـ $\tilde{s}(t)$ ، وهي دالة بالزمن t .

٣- **المركبة الدورية** Period (or Cyclical) Component، وسنرمز لها بـ $p(t)$ وهي دالة بالزمن t ، وهذه **المركبة** تصف التغيرات (أو **الاهتزازات**) الرتيبة في مسار المتسلسلة الزمنية التي ليس لها نمط موسمي (كما ذكرنا سابقاً)، وهذه **المركبة** تمثل الاهتزازات ذات الأنماط التوافقية أو الشبيهة بالتوافقية.


٤- **المركبة العشوائية** (أو **المركبة غير المنتظمة**) Irregular Component، وسنرمز لها بـ N_t ، وهي متغير عشوائي متعلق بالزمن t ، وتصف هذه **المركبة** الاهتزازات غير الرتيبة في مسار المتسلسلة الزمنية، وقد تحتوي على مكونات دورية غير منتظمة Irregular Cyclical ذات تردد غير معلوم بالإضافة إلى اهتزازات أخرى لا يمكن تحديدها وفقاً للمركبات السابقة، ومن ثم سيكون لهذه **المركبة** سلوك عشوائي عند كل لحظة زمنية t ، وبالتالي فإنَّ مُثل هذه **المركبة** سيكون طورياً عشوائياً. إنَّ الطوري العشوائي $\{N_t; t \geq 0\}$ الذي يمثل الظاهر المذكورة آنفاً يكون عادة من نموذج **الضجيج الأبيض** White Noise، ولذلك يؤخذ المتغير العشوائي N_t على أنه متغير عشوائي بتوقع رياضيائي $EN_t = 0$ وتباين يساوي $\text{var } N_t = \sigma_e^2$. علماً أنَّه يُقال عن طوري عشوائي $\{N_t\}_{t \geq 0}$ إنَّه طوري ضجيج أبيض White Noise Process إذا كان ما يلي مُحققاً:

$$EN_t = 0 \quad ; \quad t \geq 0 \quad [12,1-a]$$

$$\text{cov}(N_s, N_t) = \begin{cases} \sigma_e^2 & \text{for } s = t \\ 0 & \text{for } s \neq t \end{cases} \quad ; \quad s, t \geq 0 \quad [12,1-b]$$

ويرمز لذلك بالشكل $N_t \sim \text{WN}(0, \sigma_e)$ ، وعلاوة على ذلك يأخذ عادةً كمتغير عشوائي له توزيع طبيعي، وعندئذ يصبح للبند الثاني السابق المعنى الآتي:

من أجل كل القيم الممكنة لـ t_1 و t_2 مع $t_1 \neq t_2$ سيكون كل من المتغيرين العشوائيين N_{t_1} و N_{t_2} مستقلاً، والشكل الآتي يعرض لنا أحد مسارات هذا الطوري (طوري الضجيج الأبيض).



الشكل (٧، ١٢)

لعل المرء يتساءل في هذا الموضوع عن سبب وجود المركبة العشوائية في نموذج المتسلسلة الزمنية، وكيف يُفسر الافتراض أن هذه المركبة من طبيعة الضجيج الأبيض؟

في الحقيقة إنَّ سبب وجود المركبة العشوائية في نموذج المتسلسلة الزمنية ناتج عن وجود أخطاء عديدة غير مُسيطر عليها تُرتكب أثناء أخذ القياسات المكوّنة لبيانات المتسلسلة الزمنية، وهذه الأخطاء لا يمكن تفاديها أثناء عملية القياس مثل: الدقة المحدودة لأجهزة القياس، أو الأخطاء الناتجة عن المجرب، أو عوامل خارجية لا يمكن منعها في التأثير على الدراسة المعتمدة. أمّا تفسر الافتراض من أن هذه المركبة هي من طبيعة الضجيج الأبيض (تشبيهاً بالضوء الأبيض) فإنَّ ذلك يعود إلى أن هذه الأخطاء التي ذكرناها سابقاً قد تتداخل بعضها مع بعض وتولّد أنماطاً جديدة من الأخطاء مثلها في ذلك مثل الضوء الأبيض الناتج عن تداخل الألوان الرئيسية للضوء.

(١، ٤، ١٢) ملاحظات

١- كما ذكرنا قبل قليل بأنَّ مراجع كثيرة وكذلك البرامج الإحصائية تتعامل مع المركبتين الدورية والموسمية الموصوفتين سابقاً على أنها مركبة واحدة فقط، وتصفها بالمركبة الموسمية. لكن يجب الانتباه هنا إلى أنه في حال غياب المركبة الموسمية الصافية من مسار المتسلسلة الزمنية فإنَّ المركبة الموسمية في هذه المراجع والبرامج الإحصائية هي في الواقع المركبة الدورية.

٢- في دراستنا لتحليل المتسلسلة الزمنية سنعتمد على التحليل الرباعي (أي وفقاً للمركبات الأربع) للمتسلسلة الزمنية وذلك بغية الزيادة في التوضيح لمركبات المتسلسلة الزمنية، وأمّا لدى استخدام برنامج Minitab فإنَّنا سنستخدم التحليل الثلاثي (أي وفقاً للمركبات الثلاث) للمتسلسلة الزمنية فقط؛ لأنّه يتعامل مع المركبتين الدورية والموسمية على أنها مركبة واحدة.

٣- عندما نقوم بتوليد تنبؤات في الأمثلة القادمة سوف نقدّم ونعرض هذه التنبؤات بدون إضافة المركبة العشوائية وذلك على سبيل التوضيح، علماً أنَّ معظم البرامج الإحصائية تقدّم فترات ثقة للقيم المتنبأ بها، وسنقدّم إحداها في أحد الأمثلة القادمة.

الآن قد يتساءل القارئ لماذا نقوم بدراسة وتحليل المتسلسلات الزمنية؟

إنَّ الهدف الأساس لدراسة وتحليل المتسلسلات الزمنية يكمن في التنبؤ عن قيم مستقبلية للبيانات المقدّمة، وهذا يقودنا بدوره إلى وضع الاستراتيجيات اللازمة للتحكم (إذا أمكن ذلك) في المسار المستقبلي للمتسلسلة الزمنية بحيث لا يتجاوز حدود معينة، وذلك من خلال فرض شروط معينة على معالم النموذج الممثل للمتسلسلة الزمنية. إنَّ تحقيق ذلك يتطلب الحصول على وصف دقيق للملامح الخاصّة للطوري العشوائي الذي سيولّد المتسلسلة الزمنية، ومن ثمَّ إنشاء نموذج لتفسير وشرح سلوك المتسلسلة بدلالة متغيّرات أخرى تربط القيم المشاهدة ببعض قواعد سلوك المتسلسلة الزمنية.

إذا تم توليد تنبؤات من النموذج المستنتج لمتسلسلة زمنية، فهل هذه التنبؤات المولدة ذات مصداقية؟ في الحقيقة إنَّ سبب ثقتنا بقبول تنبؤات النموذج المستنتج يعود إلى أنَّ المتسلسلة الزمنية هي مجموعة مشاهدات تتولد على التتالي مع مرور الزمن، وأنَّ هذه المشاهدات المتتالية غالباً ما تكون مرتبطة (غير مستقلة إحصائياً) بحيث يعتمد بعضها على البعض الآخر، وهذا الارتباط العشوائي بين البيانات سيؤكِّد لدينا الثقة من أنَّ المتسلسلة الزمنية ستتابع مسيرتها في المستقبل على النحو الذي سلكته من الماضي وحتى الحاضر (وفقاً للدالة التي تمثل الاتجاه العام لها).

هل يمكن استخدام النموذج الرياضي لمتسلسلة زمنية لتقدير قيم من الماضي؟ في الواقع من الأغراض الأخرى لدراسة وتحليل المتسلسلات الزمنية هي معرفة سلوك البيانات أو التخمين (التقدير) لبعض القيم الواقعة ضمن نطاق البيانات، وذلك بشكل مشابه لما سبق أن ذكرنا في تحليل الانحدار، ولهذا السبب يلاحظ أنَّ تحليل الانحدار يُعدُّ من المواضيع المهمة لدراسة تحليل المتسلسلات الزمنية. بكلمات أخرى، فإنَّه يمكن استخدام النموذج الرياضي لمتسلسلة زمنية لتقدير قيم من الماضي على أن تكون واقعة ضمن نطاق البيانات المقدَّمة.

في الحقيقة إنَّ إيجاد نموذج مناسب لتمثيل متسلسلة زمنية مُعطاة يُعدُّ من المهام الصعبة التي تحتاج إلى الكثير من البحث والتمحيص والخبرة. لقد ذكرنا أنَّ أول خطوة في دراسة المتسلسلة الزمنية هي تعيين بصمة هذه المتسلسلة، ومن ثمَّ تأتي الخطوة التالية المتمثلة باختيار نموذج رياضي مناسب للمتسلسلة الزمنية معتمدين في ذلك على بعض المقاييس الإحصائية التي تميِّز نموذجاً عن آخر. لكن في الواقع توجد نماذج كثيرة للتمثيل الرياضي للمتسلسلات الزمنية، وهذه النماذج تتدرج ما بين البسيط نسبياً والمعقَّد، والغاية الأساس من جميع هذه النماذج هو توصيف الطوريات العشوائية المُمثلة لهذه المتسلسلات الزمنية من أجل استخدامها في استنباط التنبؤات، والتحكُّم في مسارها المستقبلي إن أمكن ذلك.

في كتابنا هذا سنقدِّم، وبشيء من التفصيل، أحد النماذج البسيطة فقط؛ لكي يتبلور لدينا مفهوم المتسلسلة الزمنية بشكل مقبول، وسنترك التفاصيل المعقَّدة والنماذج التي تحتاج إلى مفاهيم متقدِّمة من نظرية الطوريات العشوائية مثل نماذج الانحدار الذاتي والمتوسطات المتحركة المتكاملة ARIMA وما يشق عنها، ونماذج التنعيم Smoothing Models، ... أما الطريقة التي سنتناولها في دراسة تحليل متسلسلة زمنية فهي طريقة التجزئة فقط.

(١٢،٢) طريقة التجزئة في تحليل متسلسلة زمنية

Decomposition Method for the Analysis of Time Series

إنَّ طريقة التجزئة (أو ما يُعرف باسم التجزئة الوصفية أيضاً) في تحليل المتسلسلات الزمنية تنطلق من خلال تجزئة العرض الخاص بالطوري العشوائي المولَّد للمتسلسلة الزمنية إلى عدَّة مركبات، وبناءً على ذلك يمكن أن ينشأ لدينا نماذج عديدة. إنَّ النموذجين الأكثر استخداماً في تحليل المتسلسلات الزمنية وفقاً لطريقة التجزئة هما:

١- نموذج الجمع Additive Model وتُستخدم من أجله العلاقة الآتية:

$$X_t = m(t) + s(t) + N_t \quad [12,2-a]$$

وفي بعض المراجع يُعرض على النحو الآتي أيضاً:

$$X_t = m(t) + p(t) + s(t) + N_t \quad [12,2-b]$$

٢- نموذج الضرب Multiplicative Model وتُستخدم من أجله العلاقة الآتية:

$$X_t = m(t) \cdot s(t) \cdot N_t \quad [12,3-a]$$

وفي بعض المراجع يُعرض على النحو الآتي أيضاً:

$$X_t = \mathbf{m}(t) \cdot \mathbf{p}(t) \cdot \mathbf{s}(t) \cdot N_t \quad [12,3-b]$$

علماً أنه لدينا في التمثيلات الأربع السابقة [12,2-a] وحتى [12,3-b] ما يلي:

$\mathbf{m}(t)$ هي دالة الاتجاه العام للمتسلسلة الزمنية،

$\mathbf{s}(t)$ هي الدالة التي تمثل المركبة الموسمية، وفي حال التمثيل بأحد النموذجين [12,2-a] أو [12,3-a] فإنها تشتمل على الحركات الاهتزازية التي تحصل في مسار المتسلسلة الزمنية بالإضافة لبعض الاهتزازات التي تظهر في مواسم معينة (المركبة الموسمية الصافية)، ولكن دورها في التمثيلين [12,2-b] أو [12,3-b] يقتصر على المركبة الموسمية الصافية التي تمثل التغيرات المتشابهة ذات التكرار المنتظم على مدى فترة من الزمن طولها هو الدورة الموسمية Seasonal Cycle.

$\mathbf{p}(t)$ في التمثيلين [12,2-b] أو [12,3-b] هي الدالة التي تمثل المركبة الدورية، وهذه الدالة (كما ذكرنا سابقاً) تمثل الحركات الاهتزازية التي تحصل في مسار المتسلسلة الزمنية بدون المركبة الموسمية الصافية.

N_t هو متغير عشوائي يُمثل المركبة العشوائية عند اللحظة الزمنية t ، وبحيث يكون الطوري العشوائي $\{N_t; t \geq 0\}$ هو طوري ضجيج أبيض.

(١٢, ٢, ١) ملاحظة


من الممكن ألا تحوي المتسلسلة الزمنية على المركبتين الدورية والموسمية أو على إحداهما، بمعنى أنه من الممكن أن تكون المتسلسلة الزمنية ممثلة باتجاهها العام مع الخطأ العشوائي فقط، وهذه الحالة تحصل عندما تكون بيانات المتسلسلة الزمنية قريبة أو واقعة على خط المنحنى الممثل للاتجاه العام للمتسلسلة الزمنية، والفقرتين / ٢ / و / ٣ / في المثال القادم (١٢, ٢, ١) توضّحان لنا ذلك. كما لاحظنا سابقاً فإن دراسة المتسلسلات الزمنية تثير الكثير من التساؤلات، وهنا يظهر بعضاً منها أيضاً.

متى نرغب باستخدام طريقة التجزئة؟

في الحقيقة يمكننا استعمال طريقة التجزئة عندما نكون راغبين في تفريق المتسلسلة الزمنية إلى اتجاه عام خطي ومركبات موسمية (دورية وموسمية) بالإضافة إلى الخطأ، أو ببساطة إذا كنّا نريد أن نتفحص طبيعة الأجزاء المكوّنة للمتسلسلة الزمنية. حيث يمكننا اختيار نموذج الجمع، أو الضرب مع الاتجاه العام، وذلك حسب سلوك بيانات المتسلسلة الزمنية.

متى نستخدم نموذج الجمع؟

يُستعمل نموذج الجمع في طريقة التجزئة لتحليل المتسلسلات الزمنية عندما يكون الاتجاه العام غير مُحدداً أو ثابتاً، وكذلك: ١- إذا كان للبيانات مطال (نمط) موسمي ثابت (انظر العرض الآتي). حيث نلاحظ أنه في هذا العرض ليس لدينا مركبة موسمية وفقاً للتعريف السابق لهذا المفهوم، وإنما لدينا مركبة دورية يمكن البحث في تعيين طول دورها.




الشكل (١٢, ٨)

٢- إذا كان حجم النمط الموسمي غير متناسب مع البيانات (أو ليس نسبياً إلى البيانات)، بمعنى أنه في حال كان للبيانات اتجاه عام صاعد فإنه لا يترافق بزيادة مطردة لمطالات المركبة الموسمية، وكذلك في حال كان للبيانات اتجاه عام هابط فإنه لا يترافق بنقصان مطردة لمطالات المركبة الموسمية. بعبارة أخرى إن مطالات المركبة الموسمية لا علاقة لها بالاتجاه العام للمتسلسلة الزمنية، فعلى سبيل المثال لو أمعنا النظر في العروض الآتية فإننا سنلاحظ في الشكل (٩، ١٢. أ) اتجاهًا عامًا صاعدًا ومركبة موسمية شبه ثابتة (غير متأثرة الاتجاه العام) مع دورة موسمية طولها يساوي 10 فجوات زمنية (10 Lags)، وكذلك في الشكل (٩، ١٢. ب) يُلاحظ وجود اتجاه عام هابط ومركبة موسمية شبه ثابتة بدورة موسمية طولها يساوي 10 فجوات زمنية، ولدينا مركبة دورية يمكن البحث عن طول دورها.



الشكل (٩، ١٢. أ)



الشكل (٩، ١٢. ب)



الشكل (٩، ١٢. ج)

لاحظ في هذا العرض الأخير (الشكل ٩، ١٢ ج)) أنه لدينا اتجاه عام هابط ومركبة موسمية شبه ثابتة أيضاً مع دورة موسمية بطول 10 فجوات زمنية أيضاً، وكذلك لدينا مركبة دورية يمكن البحث عنه طول دورها.


٣- كذلك استخدام نموذج الجمع إذا كنا نتطلع إلى الحصول على تنبؤات بعيدة المدى، ويُقصد بتنبؤات بعيدة المدى الحصول على تنبؤات لفترة زمنية قد تصل إلى طول دور كامل من أدوار المتسلسلة الزمنية.

متى نستخدم نموذج الضرب؟

يُستعمل نموذج الضرب في طريقة التجزئة لتحليل المتسلسلات الزمنية عندما نتطلع إلى تنبؤ بعيد المدى (كما هو الحال لدى النموذج الجمعي)، وكذلك إذا كان الاتجاه العام غير مُحدد أو ثابت، أو إذا كان للبيانات نمط (شكل) موسمي ذات مطال غير ثابت ومتأثر بالاتجاه العام، بمعنى أن المطالات الموسمية تتزايد في حالة الاتجاه العام الصاعد وتتناقص في حالة الاتجاه العام الهابط (انظر العرضين الآتين).



الشكل (١٠، ١٢ أ)



الشكل (١٠، ١٢ ب)

من المعلوم أنه لدى دراسة مسار متسلسلات زمنية معقدة وطويلة الأمد يصبح عرض مركباتها من خلال دوال بسيطة أمراً غير ممكن أو على الأقل صعباً جداً، وفي مثل هذه الحالات يمكن تعيين مركبات المتسلسلة الزمنية بشكل تقريبي من خلال أخذ فترة زمنية محدودة من مسار المتسلسلة الزمنية ومن ثم البحث في دالة مناسبة لها على هذه الفترة، وبعد ذلك التعويض عن القيم المقاسة الأصل x_t (التي تمثل مشاهدات المتسلسلة الزمنية الأصل) بالقيم المقدرة \hat{x}_t الناتجة عن الدالة المقدرة عند تعويض t بالقيم الممكنة لها فنحصل بذلك على متسلسلة زمنية جديدة مشاهداتها \hat{x}_t ، وهذه المشاهدات تستخدم في عملية التنبؤ.

(١٢, ٢, ٢) ملاحظات

١- في دراستنا المقبلة سنركز على استخدام نموذج الجمع فقط من أجل تحليل متسلسلة زمنية وذلك لسهولة التعامل مع هذا النموذج.

٢- إنَّ الطوري العشوائي $\{N_t; t \geq 0\}$ الذي سيرد في المركبة العشوائية للنماذج التي تُمثل المتسلسلات الزمنية هو طوري ضجيج أبيض دوماً ما لم نشر إلى خلاف ذلك صراحة، أي سيكون لدينا $N_t \sim \text{WN}(0, \sigma_e)$.

لنقم الآن بتقديم دراسة مركبات المتسلسلة الزمنية مبتدئين ذلك بالاتجاه العام $m(t)$ ، ثم تقدير المركبة الدورية $p(t)$ ، وبعد ذلك معالجة المركبة الموسمية $s(t)$ ، وأخيراً إضافة المتغير العشوائي N_t إلى النموذج.

(١٢, ٣) تحليل الاتجاه العام لمتسلسلة زمنية

Trend Analysis of a Time Series

إنَّ عملية تقدير الاتجاه العام لمتسلسلة زمنية تعتمد وبقدر كبير على تحليل الانحدار (الخطي، وغير الخطي)، ولذلك يُفترض على المرء أن يكون لديه بعض المعارف المتعلقة بتقنيات الانحدار الخطي وغير الخطي قبل البدء بدراسة وتعيين الاتجاه العام لمتسلسلة زمنية.

لقد قمنا في الفصل الثالث بشرح الانحدار الخطي ومعالجة بعض الحالات التي يمكن رتبها إلى خطية، وذكرنا أنَّ هناك حالات من الانحدار غير الخطي لا يمكن (أو من الصعب) خطيتها، ومنها على سبيل المثال لا الحصر كثيرات الحدود من الدرجة $2 \leq n$.

سنقدِّم من خلال هذه الفقرة بعض الطرائق (البسيطة والعملية) المستخدمة في تعيين الدالة المقدَّرة للمسار (أو التوجُّه) الذي تسلكه مجموعة بيانات عينة مأخوذة من مسار متسلسلة زمنية مُعطاة، وسيكون هذا التقديم من خلال أمثلة تُرد تباعاً.

(١٢, ٣, ١) تقدير الاتجاه العام بوساطة مستقيم

يمكننا في الواقع تقدير الاتجاه العام لمتسلسلة زمنية بوساطة مستقيم، وذلك باستخدام تحليل الانحدار الخطي البسيط كما قدَّم في الفصل الثالث من هذا الكتاب. لذلك سنلاحظ أنَّ تحليل الانحدار سيلعب دوراً مهماً في تحليل الاتجاه العام لمتسلسلة زمنية.

(١٢, ٣, ١, ١) مثال


لتكن لدينا البيانات الآتية لعينة مأخوذة من مسار متسلسلة زمنية موكدة من طوري عشوائي $\{X_t; t \geq 0\}$ مُعطى بالعلاقة الآتية:

$$X_t = 0.1t + \sin(2\pi/6)t + N_t$$

الجدول (١٢, ٥)

Lag	0	1	2	3	4	5	6	7	8	9
x_t	-0.45	1.24	1.02	0.39	-0.55	-0.99	0.42	1.72	2.47	0.58
Lag	10	11	12	13	14	15	16	17	18	
x_t	-0.57	0.98	1.08	3.28	2.18	1.012	0.58	1.03	2.22	

فنجِد أنَّ لبصمة بيانات هذه العينة الشكل الآتي وموضَّحاً عليه الاتجاه العام الخطي:



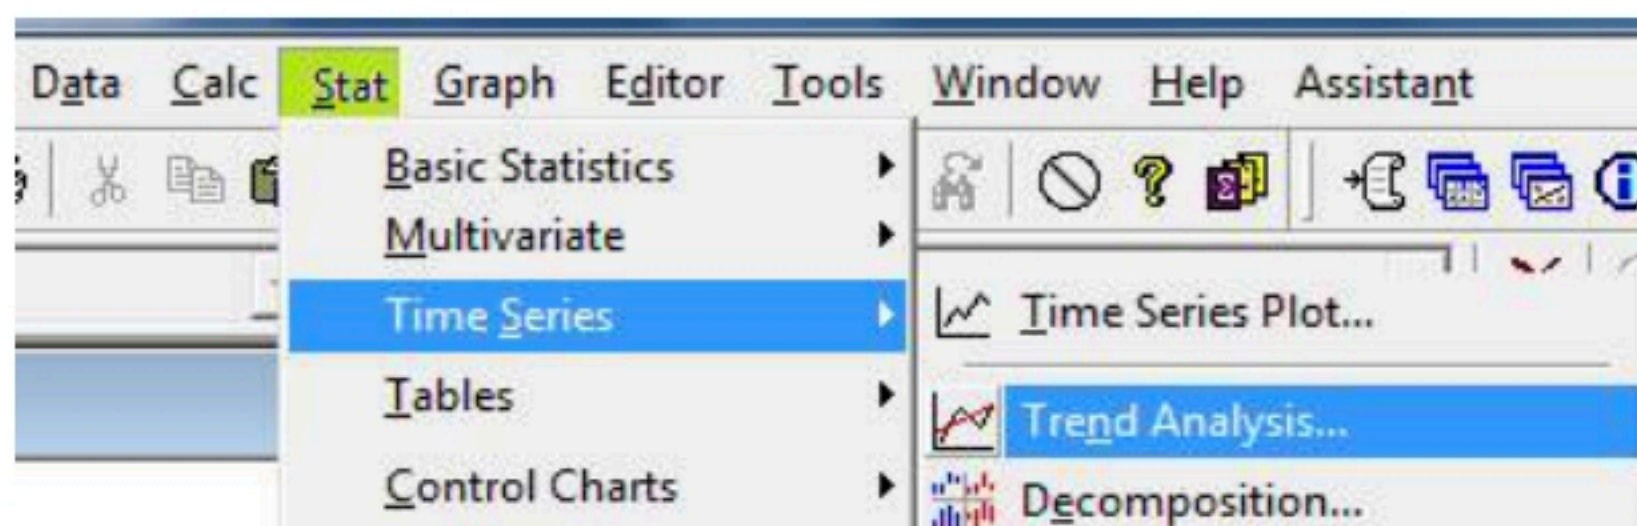
الشكل (١٠, ١٢)

علماً أنَّ معادلة مستقيم المربعات الصغرى الممثل للاتجاه العام الخطي لها العرض الآتي:

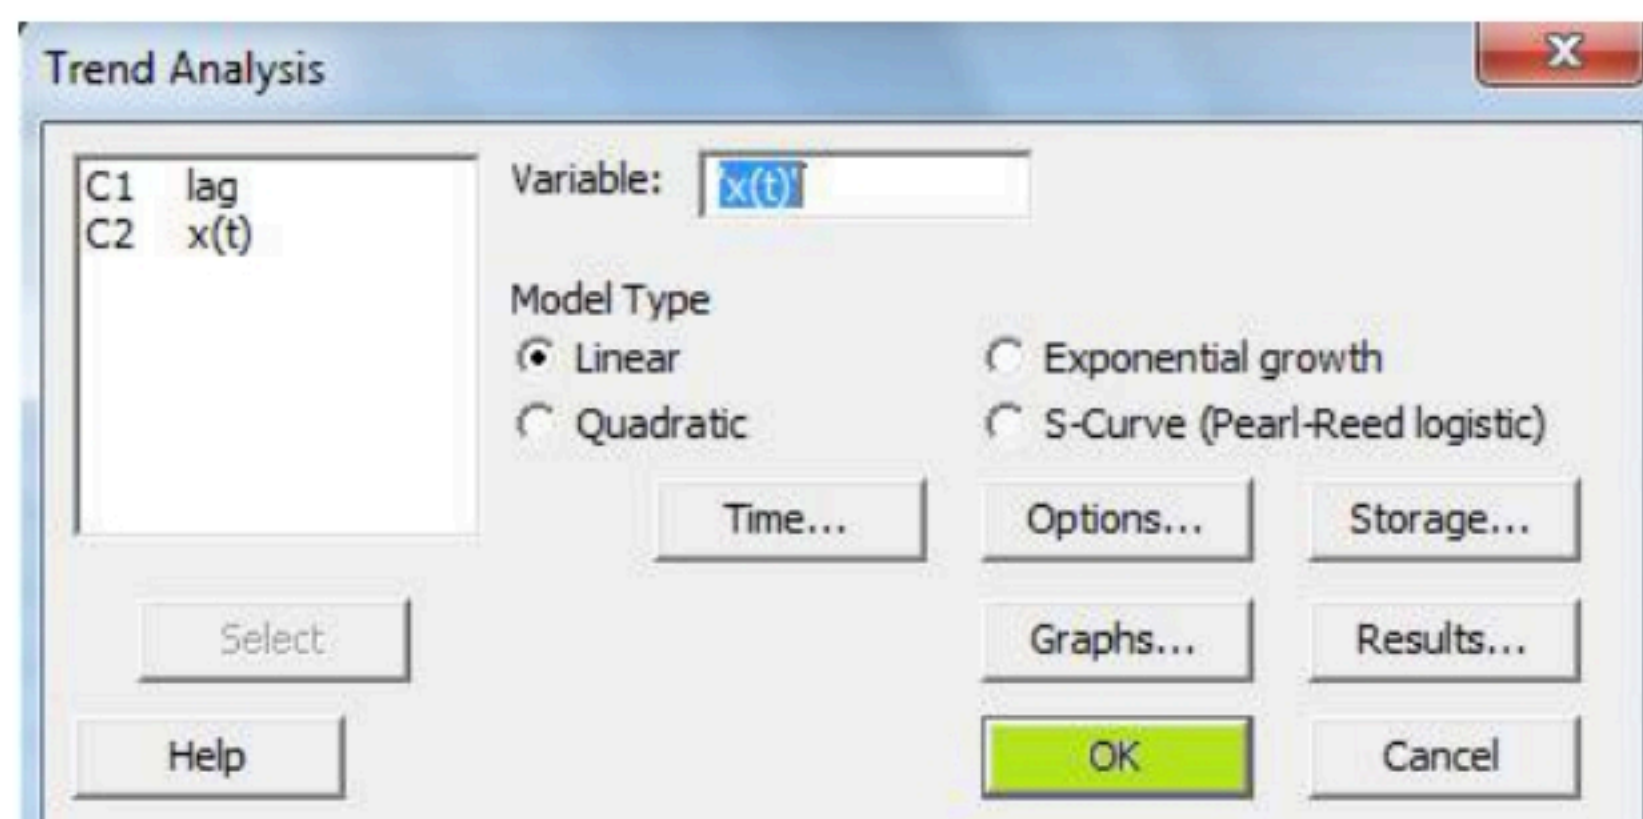
$$m(t) = 0.025 + 0.0909 t$$

ومن الممكن استخدام برنامج Minitab للحصول على الاتجاه العام الخطي السابق وذلك وفقاً للخطوات الآتية (والموضحة بالرسوم التالية أيضاً):

Stat → Time Series → Trend Analysis → For Variable insert x_t in free space → Activation Linear → OK.



ومن ثمَّ



ويمكننا هنا تغيير وحدة القياس وبعض الخصائص من خلال أيقونة Time و Options فنحصل الشكل (١٠, ١٢).

(٢, ٣, ١٢) تقدير الاتجاه العام بوساطة كثيرة حدود

قد يصادفنا في كثير من الحالات أنَّ الاتجاه العام لمتسلسلة زمنية له منحى يمكن تمثيله بكثيرة حدود من درجة ما يبحث في تعيينها. في الحقيقة إنَّ استخدام كثيرات الحدود (إن أمكن ذلك) في تقدير الاتجاه العام لمتسلسلة زمنية يُعطينا ميزة جيدة، وهذه الميزة تكمن في إمكانية رفع درجة كثيرة الحدود حتى الحصول على نموذج مناسب للاتجاه العام.

من الطرائق المستخدمة في تقدير الاتجاه العام لمتسلسلة زمنية بوساطة كثيرات الحدود ما يُعرف باسم **طريقة الفروق المتتالية**. إنَّ طريقة الفروق المتتالية لتعيين الدالة الممثلة لكثيرة حدود لبيانات مُعطاة تُعدّ من الطرائق الجيدة والعملية في تقدير كثيرات الحدود لمتسلسلة زمنية، وسنوجز شرحها فيما يلي.

(١, ٢, ٣, ١٢) طريقة الفروق المتتالية لتعيين كثيرة الحدود Successive Differences Method to Determine a Polynomial

إنَّ **طريقة الفروق المتتالية** لتعيين كثيرة الحدود المُقدَّرة للاتجاه العام لمتسلسلة زمنية x_1, x_2, \dots, x_n (بيانات مرتبة زمنياً) تقوم على الأسس الآتية:

١- نفترض أنَّ كثيرة الحدود المُقدَّرة للاتجاه العام للمتسلسلة الزمنية لها العرض الآتي:

$$m(t) = a_0 + a_1 t + a_2 t^2 + \dots + a_n t^n$$

٢- نقوم بحساب الفروق المتتالية:

$$\Delta^k x_t = \Delta^{k-1} x_{t+1} - \Delta^{k-1} x_t \quad ; k \in \mathbb{N}, t \in \{1, 2, \dots, \tau - k + 1\}$$

علماً أنَّ k هو عدد الفروق المتتالية المستخدمة و τ عدد البيانات المُقدَّمة، وكذلك لدينا:

$$\Delta^1 x_t := \Delta x_t = x_{t+1} - x_t \quad ; t = 1, 2, 3, \dots, \tau - 1$$

$$\Delta^0 x_t = x_t \quad ; t = 1, 2, 3, \dots, \tau$$

٣- حساب قيم المتوسط والتباين للفروقات المتتالية (التي عددها k) من خلال العلاقات الآتية:

$$\overline{\Delta^k x_t} = \frac{1}{\tau - k} \sum_{t=1}^{\tau-k} \Delta^k x_t$$

$$S_k^2 := \frac{1}{\tau - k} \sum_{t=1}^{\tau-k} \left(\Delta^k x_t - \overline{\Delta^k x_t} \right)^2$$

٤- نقوم بحساب المقادير الآتية:

$$V_k := S_k^2 \cdot \binom{2k}{k}^{-1}$$

ومن ثَمَّ حساب النسب $\frac{V_k}{V_{k+1}}$ من أجل كل قيم k المستخدمة في حساب الفروق المتتالية.

٥- نقوم بأخذ أول قيمة لـ k يكون من أجلها $\frac{V_k}{V_{k+1}}$ أقرب ما يكون من الواحد كتقدير لقيمة n وسنرمز لها بـ \hat{n} .

٦- بعد معرفة درجة كثيرة الحدود n نقوم بتعيين أمثال كثيرة الحدود $a_0, a_1, \dots, a_{\hat{n}}$ على النحو الآتي:

أ - نقوم باستخدام التحويل الآتي على الدليل t (تنفيذ عملية انسحاب لمحور الزمن) من خلال وضع:

$$r := \begin{cases} t - \bar{t} = \left(t - \frac{1+\tau}{2} \right) & \text{for } \tau \text{ odd} \\ 2(t - \bar{t}) = 2 \left(t - \frac{1+\tau}{2} \right) & \text{for } \tau \text{ even} \end{cases} \quad (1)$$

ب- بناءً على قيمة r التي نحصل عليها يكون لدينا:

$$\hat{a}_k = \frac{\overline{\Delta^k x_t}}{k} \quad ; \text{for } k \geq 1 \quad (2)$$

$$\hat{a}_0 = \frac{1}{\tau} \left[\sum_r x_r - \hat{a}_2 \sum_r r^2 \right] \quad (3)$$

ج- نعوض عن \hat{a}_k بما يساويها من (2) و (3) في الصيغة الآتية:

$$\hat{m}(r) = \sum_{k=0}^{\hat{n}} \hat{a}_k r^k \quad (4)$$

علماً أنَّ \hat{n} هي درجة كثيرة الحدود المقدَّرة سابقاً.

٧- في هذه الخطوة الأخيرة نعوض عن كل r بما يساويها من (1) في الصيغة (4) فنحصل على كثيرة الحدود المطلوبة.


(٢, ٢, ٣, ١٢) مثال

لتكن لدينا البيانات الآتية لعينة مأخوذة من مسار متسلسلة زمنية:

الجدول (١٢, ٦ أ)

Lag	1	2	3	4	5	6	7	8	9	10	11	12
x_t	50	35	26	14	8	3	5	14	26	35	50	64

ف نجد أنَّ لبصمة هذه المتسلسلة الزمنية الشكل الآتي:



الشكل (١١, ١٢ أ)

ف نلاحظ في هذا العرض أنَّ المتسلسلة الزمنية المعطاة لا تحتوي على مركبة موسميّة، وحتى المركبة الدورية فإنّها ليست واضحة المعالم أيضاً، وكأنَّ الاتجاه العام هو المركبة غير العشوائية الوحيدة في هذه المتسلسلة الزمنية، وكذلك نلاحظ أنَّ مسارها له شكل بياني لدالة كثيرة حدود من درجة ما (يبحث في تعيينها).

الآن لتقدير الاتجاه العام لهذه المتسلسلة الزمنية سنستخدم طريقة الفروق المتتالية، ولذلك سنفترض أنَّ كثيرة الحدود المقدَّرة للاتجاه العام لهذه للمتسلسلة الزمنية هي:

$$m(t) = a_0 + a_1 t + a_2 t^2 + \dots + a_n t^n$$

ولنقم بحساب الفروقات المتتالية حتى المرتبة السادسة فنجدها كما في الجدول الآتي:

الجدول (٦، ١٢.ب)

<i>s</i>	-11	-9	-7	-5	-3	-1	1	3	5	7	9	11
<i>t</i>	1	2	3	4	5	6	7	8	9	10	11	12
<i>x_t</i>	50	35	26	14	8	3	5	14	26	35	50	64
Δ ¹ <i>x_t</i>	-15	-9	-12	-6	-5	2	9	12	9	15	14	
Δ ² <i>x_t</i>		6	-3	6	1	7	7	3	-3	6	-1	
Δ ³ <i>x_t</i>			-9	9	-5	6	0	-4	-6	9	-7	
Δ ⁴ <i>x_t</i>				18	-14	11	-6	-4	-2	15	-16	
Δ ⁵ <i>x_t</i>					-32	25	-17	2	2	17	-31	
Δ ⁶ <i>x_t</i>						57	-42	19	0	15	-48	

ولنقم بحساب المقدير $S_k^2 \cdot \binom{2k}{k}^{-1}$ ، ومن ثمَّ حساب النسب $\frac{V_k}{V_{k+1}}$ علماً أنَّ *k* هو عدد الفروق المتتالية التي استخدمت، وقيم التباينات *S_k²* يجب أن تُحسب لكل من البيانات *x_t* والفروقات Δ^{*k*}*x_t* المستخدمة في الجدول السابق، فنجدها من أجل مثالنا هذا كما في الجدول الآتي (٦، ١٢.ج):

الجدول (٦، ١٢.ج)

قيم	المتوسط لقيم	التباين لقيم
<i>t</i>	6.5	
<i>x_t</i>	27.5	359.42
Δ ¹ <i>x_t</i>	1.27	111.29
Δ ² <i>x_t</i>	2.9	15.09
Δ ³ <i>x_t</i>	-0.78	44.39
Δ ⁴ <i>x_t</i>	0.25	147.19
Δ ⁵ <i>x_t</i>	-4.86	432.98

ومن ثمَّ يكون لدينا ما يلي:

الجدول (٦، ١٢.د)

<i>k</i>	0	1	2	3	4	5	6
$\binom{2k}{k}$	1	2	6	20	70	252	924
<i>S_k²</i>	359.42	111.29	15.09	44.39	147.19	432.98	1317.139
<i>V_k</i>	359.42	55.645	2.515	2.220	2.102	1.817	1.425
$\frac{V_k}{V_{k+1}}$	6.459	22.125	1.133	1.056	1.157	1.275	

وهكذا نجد أنَّ أول قيمة لـ k يكون من أجلها $\frac{V_k}{V_{k+1}}$ أقرب ما يكون من الواحد هي $k = 3$ ، ومن ثم تكون القيمة المقدَّرة لـ n هي $\hat{n} = 3$.

الآن وبعد معرفة درجة كثيرة الحدود التي يجب أخذها نقوم بتعيين معالم كثيرة الحدود $m(t) = a_0 + a_1 t + a_2 t^2 + a_3 t^3$ على النحو الآتي:

أ- نقوم بتحويل الدليل t إلى دليل آخر r من خلال وضع التحويل $r = 2(t - \bar{t})$ لأنَّ τ زوجي، فيكون لدينا ما يلي:

الجدول (٦، ١٢. هـ)

t	1	2	3	4	5	6	7	8	9	10	11	12	sum
r	-11	-9	-7	-5	-3	-1	1	3	5	7	9	11	
r^2	121	81	49	25	9	1	1	9	25	49	81	121	572

ب- بناءً على قيمة r المحسوبة في الجدول السابق يكون لدينا:

$$\hat{a}_1 = \overline{\Delta^1 x_t} = 1.27 \quad \& \quad \hat{a}_2 = \frac{\overline{\Delta^2 x_t}}{2} = \frac{2.9}{2} = 1.45 \quad \& \quad \hat{a}_3 = \frac{\overline{\Delta^3 x_t}}{3} = \frac{-0.78}{3} = -0.26$$

ومن ثمَّ ينتج لدينا:

$$\hat{a}_0 = \frac{1}{\tau} \left[\sum_r x_r - \hat{a}_2 \sum_r r^2 \right] = \frac{1}{12} [330 - 1.45 \times 572] = -41.62$$


ج- نعوض في صيغة كثيرة الحدود $\hat{m}(r) = \sum_{k=0}^{\hat{n}} \hat{a}_k r^k$ علماً أنَّ \hat{n} هي درجة كثيرة الحدود المقدَّرة سابقاً فنحصل على العرض الآتي:

$$\begin{aligned} \hat{m}(r) &= -41.62 + 1.27 r + 1.45 r^2 - 0.26 r^3 \\ &= -41.62 + 1.27 [2(t - 6.5)] + 1.45 [2(t - 6.5)]^2 - 0.26 [2(t - 6.5)]^3 \end{aligned}$$

والتي نحصل منها أنَّ لكثيرة الحدود المقدَّرة للاتجاه العام لهذه المتسلسلة الزمنية العرض الآتي:


$$\hat{m}(t) = 758.15 + 190.78 t + 46.36 t^2 + 2.08 t^3$$

ولرسمها البياني الشكل الآتي.



الشكل (١١، ١٢. ب)

أما إذا أردنا استخدام برنامج Minitab في تقدير الاتجاه العام لهذه المتسلسلة الزمنية فإنه سيقدم لنا كثيرة حدود من الدرجة الثانية فقط كتقدير مناسب للمشاهدات المُعطاة، ومعادلتها $\hat{m}(t) = 69.64 - 20.76t + 1.7128t^2$ ، ولها العرض البياني الآتي:




الشكل (١١، ١٢ ج)

لاحظ جودة طريقة الفروق المتتالية في عملية التقدير بسبب إعطاء كثيرة حدود من درجة أعلى مما يقدمه برنامج Minitab الذي أدى إلى توفيق أفضل للبيانات، ولكن هذا لا يُعد قاعدة عامة، فلو كانت كثيرة الحدود الملائمة للبيانات هي كثيرة حدود من الدرجة الثانية فعلاً لوجدنا أن النموذج الذي يقدمه برنامج Minitab أكثر دقة من ذلك الذي تقدمه طريقة الفروق المتتالية. كما نلاحظ هنا أن النقاط الممثلة لبيانات المتسلسلة الزمنية قريبة من منحنى الاتجاه العام، ولذلك يمكننا وبخطأ صغير نسبياً استخدام معادلة منحنى الاتجاه العام $\hat{m}(t)$ لهذه المتسلسلة الزمنية من أجل الحصول على تنبؤات جيدة، فمن أجل المتسلسلة الزمنية السابقة نحصل على التنبؤات المقدمة في الجدول الآتي:

الجدول (٦، ١٢ و)


t	1	2	3	4	5	6	7	8	9	10	11	12
x_t	50	35	26	14	8	3	5	14	26	35	50	64
t	13		14		15		لحظات زمنية مستقبلية					
\hat{x}_t	89.22		114.71		143.62		القيم المتنبأ بها					

وتمثيلها البياني يعرضه الشكل الآتي:



الشكل (١١، ١٢ د)

وباستخدام برنامج Minitab نجد العرض الآتي للتوفيق والتنبؤات:



الشكل (١١، ١٢. هـ)

(١٢، ٣، ٣) تقدير الاتجاه العام بوساطة دوال النمو Estimate the Trend by Growth Function

من النماذج الشهيرة التي لها دور مهم في تقدير مسار بعض المسلسلات الزمنية ما يُعرف باسم **متسلسلات النمو** Growth Time Series. حيث تُعدّ متسلسلات النمو من النماذج المهمة التي لها تطبيقات في ميادين علمية متعددة مثل الاقتصاد، والعلوم الطبيعية، والطب و...، وبسبب أهميتها سنقوم باستنتاج نموذج دالة النمو من خلال المثالين التطبيقين الآتيين.

(١٢، ٣، ٣، ١) أمثلة

١- لدى مراقبة سرعة نمو طفل منذ الولادة وحتى عام كامل (قبل دخول مؤثرات خارجية تؤثر في نمو الطفل كتغيير طريقة الطعام والسير و...) وجد أنّ سرعة نمو جسم هذا الطفل مع مرور الزمن t تخضع للمعادلة التفاضلية الآتية:

$$\frac{d m(t)}{dt} = \frac{b}{m} m(t)(m - m(t)) \quad (1)$$

علماً أنّ $0 < m$ يُمثّل الوزن النهائي للطفل، و $0 < b$ يمثّل ثابت سرعة النمو للطفل، وأمّا $m(t)$ فإنّه يمثّل وزن الطفل عند لحظة زمنية معينة t .

الآن بضرب المعادلة (1) بـ $\frac{1}{m(t)}$ ينتج لدينا العلاقة الآتية:


$$\frac{d m(t)}{dt} \frac{1}{m(t)} = \frac{b}{m} (m - m(t)) \quad (2)$$

حيث نلاحظ أنّ الطرف الأيسر من العلاقة (2) يمثّل السرعة النسبية لنمو الطفل، وهذه العلاقة الأخيرة هي معادلة خطية بـ $m(t)$ حلّها من الشكل:


$$m(t) = \frac{m}{1 + a e^{-bt}} \quad (3)$$

علماً أنّ الثابت $0 < a$ ينتج من الشرط الحديّ $\lim_{t \rightarrow \infty} m(t) = m$ والذي يوافق القيمة العظمى للسرعة النسبية لنمو جسم الطفل، حيث إنّ t_{∞} ترمز إلى أكبر قيمة ممكنة لـ t .

من أجل أخذ تصور أوضح حول سلوك هذه الدالة الممثّلة بالعلاقة (3) سنعرض الرسوم البيانية لهذه الدالة من أجل قيمة ثابتة لـ m وقيم متعددة لكل من a و b ، فنجد لها العروض الآتية:



الشكل (١٢، ١٢.أ)



الشكل (١٢، ١٢.ب)

إنّ الدالة الممثلة بالعلاقة (3) تُعرف باسم **الدالة المنطقية** Logistic Function، وتُسمى **دالة النمو** Growth Function أيضاً، وهذه المعادلة تحوي ثلاث معالم ولتقديرها نقوم بخطيتها (بتحويلها إلى معادلة خطية) بعد أن نفترض أنّ قيمة m معلومة لأنّها تُحسب من الشرط الحدي $\lim_{t \rightarrow t_{\infty}} m(t) = m$ ، ولأجل خطية الدالة الممثلة بالعلاقة (3) نكتب:

$$m = m(t) + m(t) a e^{-bt}$$

ومنه يكون لدينا:

$$\ln(m - m(t)) = \ln m(t) + \ln a - bt$$

وأخيراً ينتج لدينا:

$$\ln \frac{m - m(t)}{m(t)} = \ln a - bt$$

وبوضع $a^* = \ln a$ و $z_t = \ln \frac{m - m(t)}{m(t)}$ نحصل على العلاقة الخطية $z_t = a^* - b t$ (خطية بـ t)، علماً أنّ قيم $m(t)$ تُعيّن من القيم المشاهدة x_t وذلك بوضع $m(t) = x_t$. بعد ذلك نقوم بتعيين مستقيم المربعات الصغرى للبيانات (t, z_t) عندما نمسح كل القيم الممكنة لـ t ، ومن ثمّ نقوم بالتعويض بشكل عكسي لما افترضناه للخطية فنحصل على معادلة المنحنى المقدّر للاتجاه العام للبيانات المقدّمة للمتسلسلة الزمنية.


المثال الآتي يُعدّ من الأمثلة التي تنسجم مع تطبيقات دالة النمو أيضاً.

٢- لدينا تجربة لقياس سرعة ردود الأفعال عند الأشخاص من خلال مؤثرات صوتية وضوئية وحركية وبحيث يمكن لأي شخص أن ينال 20 نقطة من 20 نقطة كحد أقصى. أخضع شخص لهذه التجربة وقام بتكرار هذه التجربة على مدى سبعة أيام متتالية مستفيداً من خبرته في كل تكرار لتحصيل نتيجة أفضل في التكرار اللاحق فكانت نتائجه على النحو الآتي:

الجدول (١٢، ٧)

t	0	1	2	3	4	5	6
x_t	1	2	5	10	14	18	19

أما بصمة المتسلسلة الزمنية لنتائج الشخص المدرب فلها الشكل الآتي:



شكل (١٢، ١٣)

فلاحظ أن لبصمة هذه المتسلسلة شكل دالة نمو، ولذلك سنستخدم النموذج السابق في تقدير الاتجاه العام لهذه المتسلسلة الزمنية. حيث لدينا في هذا التطبيق $m = \lim_{t \rightarrow t_{\infty}} m(t) = 20$ وكذلك:


$$z_t = \ln \frac{m - m(t)}{m(t)} = \ln \frac{20 - x_t}{x_t}$$

فيكون لـ z_t القيم الموضحة في الجدول الآتي:

الجدول (١٢، ٧) ب

t	0	1	2	3	4	5	6
x_t	1	2	5	10	14	18	19
z_t	2.94	2.19	1.09	0	-0.84	-2.19	-2.94

وبتعيين مستقيم المربعات الصغرى للبيانات (t, z_t) عندما نمسح كل القيم الممكنة لـ t ، فإننا سنجد لها المعادلة $z_t = a^* - b t = 3.07 - 1.01 t$ ولرسمها البياني الشكل الآتي:




الشكل (١٢، ١٣) ب

ومن المعادلة السابقة نجد أن $b = -1.01$ و $a = e^{a^*} = e^{3.07} = 21.565$ ، ومن ثمَّ يصبح للدالة المقدَّرة للاتجاه العام للمتسلسلة الزمنية المُعطاة العرض الآتي:

$$\hat{m}(t) = \frac{m}{1 + a e^{-bt}} = \frac{20}{1 + 21.565 e^{-1.01t}}$$

ومنه يكون لدالة الاتجاه العام للمتسلسلة الزمنية المُعطاة الشكل الآتي:




الشكل (١٣، ١٢ ج)

بالطبع كان بإمكاننا تعيين دالة الاتجاه العام للمتسلسلة الزمنية المُعطاة باستخدام برنامج Minitab باختيار فقرة تحليل الاتجاه العام Trend، ومن ثمَّ تفعيل خيار S-Curve فنحصل على العلاقة الآتية كدالة مقدَّرة للاتجاه العام للمتسلسلة الزمنية المُعطاة:

$$\hat{m}(t) = \frac{100}{4.932 + 277.283 \times 0.3752^t}$$

ولرسمها البياني الشكل الآتي:



الشكل (١٣، ١٢ د)

فلاحظ أنَّ بيانات المتسلسلة الزمنية قريبة من منحنى الاتجاه العام، ولذلك يُمكننا وبخطأ صغير نسبياً استخدام معادلة منحنى الاتجاه العام $\hat{m}(t)$ لهذه المتسلسلة الزمنية (ومن أجل أي من النموذجين السابقين) من أجل الحصول على تنبؤات جيدة. حيث نجد التنبؤات للفجوات الزمنية الثلاث التالية 8، 9 و 10 مقدَّمة كما في الجدول الآتي:

الجدول (٧، ١٢ هـ)

t الأيام										
0	1	2	3	4	5	6	7	8	9	10
1	2	5	10	14	18	19	19.64	19.87	19.95	19.98
x_t البيانات الأصل						\hat{x}_t قيم متنبأ بها				

والرسم البياني لهذه البيانات هو الشكل السابق (١٣، ١٢ د) نفسه.

(١٢, ٣, ٣, ٢) ملاحظات

١- كما لاحظنا، فإنه إذا كانت بيانات المتسلسلة الزمنية قريبة جداً من منحنى الاتجاه العام كما في المثالين (١٢, ٣, ٢, ٢) و (١٢, ٣, ٣, ١) / ٢ /، فعندئذ يمكننا (وبخطأ صغير نسبياً) استخدام معادلة منحنى الاتجاه العام من أجل التنبؤ، حيث يمكننا الحصول على تنبؤات جيدة.

٢- إذا لوحظ أن بيانات المتسلسلة الزمنية تتبع بتبعثر بحيث يصعب معها اختيار المنحنى الذي سيمثل الاتجاه العام لهذه المتسلسلة الزمنية؛ فإنه يمكن استخدام كثيرات الحدود لتعيين الاتجاه العام، وذلك لأنه (وكما ذكرنا سابقاً) من فوائد استخدام كثيرات الحدود رفع درجة كثيرة الحدود للحصول على منحنى أكثر توافقاً مع البيانات المُعطاة. لكن عندما تصبح درجة كثيرة الحدود أكبر من (2) فإنَّ معالم كثيرة الحدود تصبح صعبة التفسير أو عديمة التفسير، فعلى سبيل المثال إذا كانت كثيرة الحدود من الدرجة الثانية:

$$m(t) = a + bt + ct^2$$

فعندئذ يمكن تفسير الأمثال a ، b و c على النحو الآتي:

الثابت a يدل على القيمة الابتدائية للمتسلسلة الزمنية أي إنَّ $a = \hat{m}(0)$ ، الثابت b يدل على سرعة تزايد بيانات المتسلسلة الزمنية، وأما الثابت c فإنه يدل على تسارع (العجلة) التزايد لبيانات المتسلسلة الزمنية، فلو كانت كثيرة الحدود من الدرجة الثالثة:

$$m(t) = a + bt + ct^2 + dt^3$$

فما هو التفسير الموافق لـ d ؟

٣- ذكر في المرجع [33] أنه يمكن للمرء أن يستخدم ناتج طريقة التجزئة للتنبؤ حتى فترة طولها يساوي نصف طول الفترة الزمنية التي استخدمت في الدراسة، ولكن أرى أن هذا الطرح ينطوي على شيء من عدم الدقة في الحالة العامة وخاصة إذا كانت المتسلسلة الزمنية تحوي مرگبات موسمية أو دورية، فعندئذ التنبؤ لفترة زمنية تزيد عن طول دور كامل ليس له معنى في الواقع العملي.

في بعض الحالات قد يكون اهتمامنا منصّباً على معرفة إن كان لمتسلسلة زمنية قيد الدراسة اتجاهًا عامًا مطّردًا أو لا، وبشكل خاص عندما يصعب علينا استنباط الاتجاه العام من خلال النظر إلى بصمة المتسلسلة الزمنية، ومثال على ذلك الشكل (١٥, ١٢. أ) في المثال القادم / ٢ / من (١٢, ٣, ٤, ١). في مثل هذه الحالات توجد اختبارات عديدة للبت في مثل هذه المسألة ومنها الاختبار الآتي.

(١٢, ٣, ٤) اختبار الفرق لـ نويمان Neumann Deference Test

إنَّ اختبار الفرق لـ نويمان يبيّن إن كان لمتسلسلة زمنية قيد الدراسة اتجاهًا عامًا مطّردًا أم لا، وذلك من خلال اختبار الاستقلال لبيانات مأخوذة من مسار متسلسلة زمنية، فلو افترضنا أنه لدينا عيّنة x_1, x_2, \dots, x_τ مأخوذة من مسار متسلسلة زمنية على فترات زمنية متساوية الطول. عندئذ اختبار الفرق لـ نويمان يقوم على اختبار الفرضية الابتدائية الآتية:

البيانات x_1, x_2, \dots, x_τ هي قيم عشوائية مستقلة: H_0

مقابل الفرضية البديلة:

البيانات x_1, x_2, \dots, x_τ هي قيم عشوائية مرتبطة: H_A

وذلك عند مستوى من الأهمية α .

من أجل اتخاذ القرار بشأن هذا الاختبار نقوم بما يلي:

١- نحسب الفروق المتتالية الأولى:

$$\Delta x_t = x_{t+1} - x_t \quad ; t = 1, 2, 3, \dots, \tau - 1$$

٢- نحسب المتوسطات لمربعات الفروقات السابقة:

$$\overline{\Delta x_t^2} = \frac{1}{\tau-1} \sum_{t=1}^{\tau-1} \Delta x_t^2 \quad ; t = 1, 2, 3, \dots, \tau-1$$

٣- نقوم بحساب قيمة الإحصاءة:

$$NE := \frac{\overline{\Delta x_t^2}}{s^2} = \overline{\Delta x_t^2} \cdot \left(\frac{1}{\tau-1} \sum_{t=1}^{\tau} (x_t - \bar{x})^2 \right)^{-1} \quad [12,4]$$

علماً أنَّ s هو الانحراف المعياري للبيانات x_1, x_2, \dots, x_τ .

٤- إذا كان:

أ- حجم العينة $\tau < 60$ فإننا نضع:

$$q_{1-\alpha} = 2 - 2 \cdot \mathcal{Z}_{1-\alpha} \sqrt{\frac{\tau-2}{(\tau-1)(\tau+1)}} \quad [12,5]$$

علماً أنَّ $\mathcal{Z}_{1-\alpha}$ هي القيمة التي تم استخدامها في الفصول الثلاث السابقة وتستخرج من جدول التوزيع الطبيعي المعياري.

ب- حجم العينة $\tau \geq 60$ فإننا نأخذ قيمة $q_{1-\alpha}$ من الجدول الآتي والخاص بهذا الاختبار.

الجدول (٨، ١٢)

τ		10	15	20	25	30	35	40	45	50	55	60
$\alpha = 0.05$	$q_{1-\alpha}$	1.06	1.21	1.30	1.37	1.41	1.46	1.49	1.52	1.54	1.56	1.58
$\alpha = 0.01$	$q_{1-\alpha}$	0.75	0.92	1.04	1.13	1.20	1.25	1.29	1.33	1.36	1.39	1.41

٥- اتخاذ القرار: إذا كان $q_{1-\alpha} > NE$ فعندئذ تُرفض الفرضية الابتدائية H_0 عند مستوى الأهمية α ، وهذا يعني أنَّ البيانات المقدَّمة مرتبطة عند مستوى الأهمية α ، ومن ثمَّ المتسلسلة الزمنية تملك اتجاهًا عامًا مطَّردًا عند هذا المستوى من الأهمية. بالطبع توجد اختبارات أخرى لتحديد إن كان لمتسلسلة زمنية اتجاهًا عامًا مطَّردًا أم لا، ومنها Moore-Wallis Test وكذلك اختبار Staurt-Cox Test (انظر [33]).


(١، ٤، ٣، ١٢) أمثلة

١- لتكن لدينا المشاهدات المقدَّمة في الجدول الآتي والمأخوذة من مسار متسلسلة زمنية تصف عدد الأخطاء المرتكبة في مباريات فريق لكرة القدم منذ بداية الدوري العام السنوي.

الجدول (٩، ١٢. أ)

t	1	2	3	4	5	6	7	8	9	10
x_t	17	9	5	8	9	4	2	4	3	2

فنجِد لبصمة هذه المتسلسلة الزمنية العرض الآتي:



الشكل (١٤، ١٢)

الآن لنختبر إن كانت هذه البيانات مستقلة بعضها عن بعض أم لا (بمعنى إن كان لهذه البيانات اتجاه عام مطرد أم لا) وذلك عند مستوى من الأهمية $\alpha = 0.05$.

الحل: من أجل ذلك علينا اختبار الفرضية الابتدائية:

البيانات x_1, x_2, \dots, x_T هي قيم عشوائية مستقلة: H_0

مقابل الفرضية البديلة:

البيانات x_1, x_2, \dots, x_T هي قيم عشوائية مرتبطة: H_A

وبحساب الفروق المتتالية الأولى (انظر الجدول (٩، ١٢. ب) للفروق المتتالية الأولى)، ومن ثمّ حساب المتوسطات لمربعات الفروقات السابقة، فإننا سنجد $\overline{\Delta x_t^2} = 13.89$ و $s^2 = 21.34$ ، ومن ثمّ تكون قيمة الإحصاء NE تساوي:

$$NE := \frac{\overline{\Delta x_t^2}}{s^2} = \frac{13.89}{21.34} = 0.65$$

الجدول (٩، ١٢. ب)

t	1	2	3	4	5	6	7	8	9	10
x_t	17	9	5	8	9	4	2	4	3	2
Δx_t	-8	-4	3	1	-5	-2	2	-1	-1	


وبما أنّ حجم العينة $n = 10$ ، ومستوى الأهمية $\alpha = 0.05$ فإنه سيكون لدينا $q_{1-\alpha} = q_{0.95} = 1.06$ (من الجدول (٨، ١٢))، وهكذا نجد أنّ $q_{1-\alpha} > NE$ ، ومن ثمّ نرفض الفرضية الابتدائية H_0 عند مستوى من الأهمية $\alpha = 0.05$ ، ومن ثمّ فإنّ عدد الأخطاء المرتكبة في مباريات هذا الفريق ليست مستقلة بعضها عن بعض، وبالتالي المتسلسلة الزمنية لظاهرة عدد الأخطاء المرتكبة في مباريات هذا الفريق تملك اتجاهًا عامًا مطردًا (وهو اتجاه عام هابط كما أظهره الشكل (١٤، ١٢)) عند مستوى الأهمية $\alpha = 0.05$.

٢- لتكن لدينا المشاهدات المقدّمة في الجدول الآتي والمأخوذة من مسار متسلسلة زمنية تصف عدد نوبات الصرع في كل شهر لدى مريض وعلى مدى 28 شهراً، ولنبحث هل كان عدد النوبات الشهرية للمريض مستقلة بعضها عن بعض أم لا؟

الجدول (١٠، ١٢. أ)

الشهر t	1	2	3	4	5	6	7	8	9	10	11	12	13	14
x_t	3	1	2	4	3	2	3	5	6	4	7	8	5	3
الشهر t	15	16	17	18	19	20	21	22	23	24	25	26	27	28
x_t	4	5	6	7	6	4	2	5	4	1	0	2	3	5

فنجند لبصمة هذه المتسلسلة الزمنية العرض الآتي:



شكل (١٥، ١٢).

الآن لنختبر إن كان للمتسلسلة الزمنية المعطاة اتجاهًا عامًا مطردًا أم لا (أي إن كانت هذه البيانات مستقلة بعضها عن بعض أم لا)، وذلك عند مستوى من الأهمية قدره $\alpha = 0.05$.

الحل: من أجل ذلك لنختبر الفرضية الابتدائية:

البيانات x_1, x_2, \dots, x_{28} هي قيم عشوائية مستقلة: H_0

مقابل الفرضية البديلة:

البيانات x_1, x_2, \dots, x_{28} هي قيم عشوائية مرتبطة: H_A

وبحساب الفروق المتتالية الأولى، ومن ثم حساب المتوسطات لمربعات الفروقات السابقة نجد ما يلي (انظر الجدول الآتي للفروق المتتالية الأولى):

الجدول (١٠، ١٢. ب)


الشهر t	1	2	3	4	5	6	7	8	9	10	11	12	13	14
x_t	3	1	2	4	3	2	3	5	6	4	7	8	5	3
Δx_t	-2	1	2	-1	-1	1	2	1	-2	3	1	-3	-2	
الشهر t	15	16	17	18	19	20	21	22	23	24	25	26	27	28
x_t	4	5	6	7	6	4	2	5	4	1	0	2	3	5
Δx_t	1	1	1	-1	-2	-2	3	-1	-3	-1	2	1	2	

فيكون لدينا $\overline{\Delta x_t^2} = 3.19$ و $s^2 = 3.921$ ، ومنه نجد أن قيمة الإحصاء NE تساوي:

$$NE := \frac{\overline{\Delta x_t^2}}{s^2} = \frac{3.19}{3.92} = 0.814$$

وبما أن حجم العينة $n = 28$ ، ومستوى الأهمية $\alpha = 0.05$ فإنه سيكون لدينا $q_{0.95} = 1.41$ (من الجدول (٨، ١٢))، وهكذا ينتج لدينا أن $q_{1-\alpha} > NE$ ، وبالتالي نرفض الفرضية الابتدائية H_0 عند مستوى من الأهمية $\alpha = 0.05$ ، ومن ثم فإن عدد نوبات الصرع الشهرية للمريض ليست مستقلة بعضها عن بعض (مرتبطة بعضها ببعض)، وهكذا نجد أن المتسلسلة الزمنية لظاهرة الصرع لدى المريض تملك اتجاهًا عامًا مطردًا عند مستوى الأهمية $\alpha = 0.05$. لاحظ صعوبة تحديد اطراد الاتجاه العام (الممثل بمستقيم الانحدار)

لهذه المسلسلة الزمنية بالعين المجردة؛ وذلك لأن ميل مستقيم الانحدار لهذه البيانات صغير جداً ويساوي -0.001642 (انظر الشكل الآتي).



الشكل (١٥، ١٢. ب)

(١٢، ٤) دراسة المركبة الدورية لمسلسلة زمنية

Study the Period Component of Time Series

الآن وبعد التعرف على مفهوم ومدلول الاتجاه العام لمسلسلة زمنية وكيفية تعيينه سنتقل إلى دراسة المركبة الدورية. في الواقع توجد طرائق عديدة لتقدير المركبة الدورية لمسلسلة زمنية، وكل طريقة تتطلب شروطاً محددة لتطبيقها، ومن هذه الطرائق (على سبيل المثال لا الحصر):

- أ- طريقة جيب التمام (أو التجيب) لـ هلبيرغ.
 - ب- طريقة تحليل الارتباط والترددات الخفية.
 - ج- طريقة العارض الدوري.
 - د- طريقة تقدير الأدوار لدى أدوار بأطوال مختلفة.
- في كتابنا هذا سنقتصر على تقديم الطريقة الأولى فقط، وهي تمتاز ببساطتها ووضوحها، ولكن لها شروط محددة لاستخدامها.

(١٢، ٤، ١) طريقة جيب التمام (أو التجيب) لـ هلبيرغ Halberg's Cosine Method

لقد قدم الرياضياتي الفرنسي هلبيرغ (1919-2013) Franz Halberg طريقة لتقدير المركبة الموسمية لمسلسلة زمنية تحتوي في مسارها على اهتزازات توافقية (جيبية أو قريبة من الجيبية)، وهذه الطريقة تنطلق من نموذج الجمع الآتي:

$$X_t = m(t) + s(t) + N_t \quad [12,6]$$

والمركبة الموسمية $s(t)$ هنا تتضمن كل من المركبة الدورية والموسمية $p(t) + s(t)$ في نموذج التجزئة ذي المركبات الأربع، ويقوم هذا الاختبار على شروط عدة يجب توفرها، وهي:

- أ- المسلسلة الزمنية تحتوي على اهتزازات توافقية.
 - ب- أعداد القياسات في كل دور متساوية على وجه التقريب، ويجب ألا يقل عن أربعة قياسات في كل دور.
- عندئذ نضع:

$$s(t) = m + \alpha \cos(\omega t + \phi) \quad [12,7]$$


علماً أنَّ:

m هي القيمة الوسطى للمتسلسلة الزمنية.

α هو سعة مطال Amplitude الاهتزاز.

ω السرعة الزاوية للاهتزاز Angular Frequency التي تساوي $\omega = \frac{2\pi}{p}$ ، علماً أنَّ p هو طول الدور Length of Period.

ϕ يمثل فرق الصفحة Acrophase بين المتسلسلة الزمنية ودالة جيب التمام (انظر الشكل الآتي).



الشكل (١٦، ١٢)

وهكذا نلاحظ أنه تحت الفرض أنَّ طول الدور معلوماً (ومن ثمَّ ω معلوماً دوماً) فإنه لدينا ثلاثة معالم يجب تقديرها وهي m ، α و ϕ ، ولتقدير هذه المعالم نقوم بما يلي:

١- نقوم بتقدير مُركبة الاتجاه العام $m(t)$ ، ومن ثمَّ نزيلها من الطرف الأيمن لنموذج المتسلسلة الزمنية من خلال وضع:

$$\tilde{X}_t := X_t - \hat{m}(t) = s(t) + N_t \quad [12,8]$$

وفي هذه الحالة يُقال عن النموذج [12,8] للمتسلسلة الزمنية إنه معدَّل اتجاهياً، أو إنَّ المتسلسلة الزمنية مقدَّمة بالعرض المُختزل.

٢- نفترض أنَّ للدالة $s(t)$ العرض $s(t) = \alpha \cos(\omega t + \phi)$. عندئذ يمكننا أن نكتب:

$$\tilde{X}_t = m + \alpha \cos(\omega t + \phi) + N_t = m + \alpha \cos(\phi) \cos(\omega t) - \alpha \sin(\phi) \sin(\omega t) + N_t$$

٣- نضع:

$$\beta = \alpha \cos \phi \quad \& \quad \gamma = -\alpha \sin \phi \quad \& \quad u(t) = \cos(\omega t) \quad \& \quad z(t) = \sin(\omega t)$$

وبالتعويض يصبح لدينا:

$$\tilde{X}_t = m + \beta \cdot u(t) + \gamma \cdot z(t) + N_t$$

وهي علاقة خطية بكلٍّ من $u(t)$ و $z(t)$ يُقدَّر فيها β و γ بطريقة المربعات الصغرى، فإذا كانت العينة المأخوذة من مسار المتسلسلة الزمنية هي x_1, x_2, \dots, x_τ ، فعندئذ تحت هذه المعطيات نضع:

$$\tilde{x}_t = x_t - \hat{m}(t) \quad ; t = 1, 2, \dots, \tau$$

والتي تُعرف باسم **البواقي** Residual الناتجة عن الاتجاه العام المُقدَّر، وفي هذه الحالة يجب أن يكون المجموع الآتي أصغرياً:

$$\sum_{t=1}^{\tau} [\tilde{x}_t - (m + \beta \cdot u(t) + \gamma \cdot z(t))]^2$$

وهذا يعني أنَّ:

$$\left(\sum_{t=1}^{\tau} [\tilde{x}_t - (m + \beta \cdot u(t) + \gamma \cdot z(t))]^2 \right)' = 0$$

ومن هذه العلاقة الأخيرة ينتج لدينا نظام المعادلات الخطية الآتية:

$$\begin{aligned}\sum_{t=1}^{\tau} \tilde{x}_t &= m \cdot \tau + \beta \sum_{t=1}^{\tau} u(t) + \gamma \sum_{t=1}^{\tau} z(t) \\ \sum_{t=1}^{\tau} \tilde{x}_t \cdot u(t) &= m \cdot \sum_{t=1}^{\tau} u(t) + \beta \sum_{t=1}^{\tau} u^2(t) + \gamma \sum_{t=1}^{\tau} u(t) \cdot z(t) \\ \sum_{t=1}^{\tau} \tilde{x}_t \cdot z(t) &= m \cdot \sum_{t=1}^{\tau} z(t) + \beta \sum_{t=1}^{\tau} u(t) \cdot z(t) + \gamma \sum_{t=1}^{\tau} z^2(t)\end{aligned}$$

والتي يمكن تقديمها بالشكل المصفوفي الآتي أيضاً:

$$\begin{pmatrix} \tau & \sum_{t=1}^{\tau} u(t) & \sum_{t=1}^{\tau} z(t) \\ \sum_{t=1}^{\tau} u(t) & \sum_{t=1}^{\tau} u^2(t) & \sum_{t=1}^{\tau} u(t)z(t) \\ \sum_{t=1}^{\tau} z(t) & \sum_{t=1}^{\tau} u(t)z(t) & \sum_{t=1}^{\tau} z^2(t) \end{pmatrix} \cdot \begin{pmatrix} m \\ \beta \\ \gamma \end{pmatrix} = \begin{pmatrix} \sum_{t=1}^{\tau} \tilde{x}_t \\ \sum_{t=1}^{\tau} \tilde{x}_{t_i} \cdot u(t) \\ \sum_{t=1}^{\tau} \tilde{x}_{t_i} \cdot z(t) \end{pmatrix}$$

وبالحل المشترك لنظام المعادلات الخطية السابقة نحصل على تقديرات المعالم m ، β و γ من خلال العلاقات الآتية على الترتيب:

$$\hat{m} = \frac{1}{\tau} \sum_{t=1}^{\tau} \tilde{x}_t \quad [12,9-a]$$

$$\hat{\beta} = \frac{2}{\tau} \sum_{t=1}^{\tau} \tilde{x}_t \cdot u(t) = \frac{2}{n} \sum_{t=1}^{\tau} \tilde{x}_t \cdot \cos(\omega t) \quad [12,9-b]$$

$$\hat{\gamma} = \frac{2}{\tau} \sum_{t=1}^{\tau} \tilde{x}_t \cdot z(t) = \frac{2}{\tau} \sum_{t=1}^{\tau} \tilde{x}_t \cdot \sin(\omega t) \quad [12,9-c]$$

وأما قيمة α فإنها تُقدَّر بوساطة العلاقة الآتية:

$$\hat{\alpha} = \sqrt{\hat{\beta}^2 + \hat{\gamma}^2} \quad [12,9-d]$$

في حين أن فرق الصفحة ϕ يُقدَّر باستخدام العلاقة الآتية:

$$\hat{\phi} = k \cdot \pi \pm \hat{\theta} \quad ; k \in \mathbb{Q} \quad [12,9-e]$$

علماً أن $\hat{\theta}$ مقدرة بـ **الراديان** وتحسب من العلاقة الآتية:

$$\hat{\theta} = \arctan \left| \frac{-\hat{\gamma}}{\hat{\beta}} \right| = \arctan \left| \frac{\hat{\gamma}}{\hat{\beta}} \right| \quad [12,9-f]$$

وتُعين إشارة $\hat{\theta}$ وقيمة k من الجدول الآتي الذي يعتمد على إشارتي $\hat{\beta}$ و $\hat{\gamma}$ معاً:

الجدول (١١، ١٢)

	$\hat{\beta} > 0$	$\hat{\beta} = 0$	$\hat{\beta} < 0$
$\hat{\gamma} > 0$	$\hat{\phi} = -\hat{\theta}$	$\hat{\phi} = -\hat{\theta}$	$\hat{\phi} = \hat{\theta} + \pi$
$\hat{\gamma} = 0$	$\hat{\phi} = \hat{\theta} - 2\pi$	لا توجد مركبة دورية	$\hat{\phi} = \hat{\theta} - \pi$
$\hat{\gamma} < 0$	$\hat{\phi} = \hat{\theta} - 2\pi$	$\hat{\phi} = -\hat{\theta} - \pi$	$\hat{\phi} = -\hat{\theta} - \pi$

بعد ذلك نعوض في صيغة المركبة الموسمية وبعد ذلك في صيغة العلاقة التي تعطي نموذج المتسلسلة الزمنية أيضاً فنحصل على النموذج الرياضي المقدّر لتلك المتسلسلة الزمنية.

(١، ١، ٤، ١٢) مثال

بالعودة إلى المثال (١، ١، ٣، ١٢) حيث لدينا متسلسلة زمنية مولدة بوساطة طوري عشوائي $\{X_t; t \geq 0\}$ مُعطى بالعلاقة الآتية:

$$X_t = 0.1t + \sin(2\pi/6)t + N_t \quad ; t \geq 0$$

فلو أمعنا النظر في بصمة العينة المأخوذة من مسار هذه المتسلسلة الزمنية (انظر الشكل (١٠، ١٢)) نلاحظ وجود ثلاثة أدوار، وطول الدور p يساوي 6 فجوات زمنية بسبب وجود ست قيم مقيسة تقريباً في كل دور، وهذا يعني أن الشروط المطلوبة لتطبيق طريقة جيب التمام لـ هلبيرغ مُحَقَّقة، ومن ثمَّ بإمكاننا استخدام طريقة جيب التمام لـ هلبيرغ لتقدير المركبة الدورية. لقد قمنا سابقاً بتقدير مركبة الاتجاه العام لهذه المتسلسلة الزمنية بوساطة الانحدار الخطي حيث كانت لدينا الدالة الخطية المقدرة لمركبة الاتجاه العام هي:

$$m(t) = 0.025 + 0.0909t$$

ومن ثمَّ لإزالة الاتجاه العام من هذه المتسلسلة الزمنية نقوم بطرح القيم المقدرة $\hat{m}(t)$ من القيم الأصل x_t وذلك من أجل كل القيم الممكنة لـ t ، فنحصل على القيم \tilde{x}_t . أي إنه لدينا:


$$\tilde{x}_t = x_t - \hat{m}(t) \quad ; t = 0, 1, \dots, 18$$

ومن أجل المتسلسلة الزمنية التي قيد الدراسة سيكون لـ \tilde{x}_t القيم الآتية:

الجدول (١٢، ١٢.أ)

t	0	1	2	3	4	5	6
\tilde{x}_t	-0.475	1.1241	0.8132	0.0923	-0.9386	-1.4695	-0.1504
t	7	8	9	10	11	12	13
\tilde{x}_t	1.0587	1.7178	-0.2631	-1.504	-0.0449	-0.0358	2.0733
t	14	15	16	17	18		
\tilde{x}_t	0.8824	-0.2685	-0.8994	-0.5403	0.5588		

ولبصمتها الشكل (١٧، ١٢.أ). لاحظ كيف أصبح اتجاهها العام أفقياً وهذا ما يُعبّر به عادة بإزالة الاتجاه العام لمتسلسلة زمنية.



الشكل (١٧، ١٢.أ)

وكذلك باستخدام العلاقات [12,9-a] وحتى [12,9-c] نجد الآتي:

$$\hat{m} = \frac{1}{19} \sum_{t=0}^{18} \tilde{x}_t = \frac{1}{19}(1.7311) = 0.0911$$

والآن لتقدير المعلمتين β و γ سنبنّي الجدول الآتي:

الجدول (١٢، ١٢.ب)

t	x_t	\tilde{x}_t	$\tilde{x}_t \cdot u(t)$	$\tilde{x}_t \cdot z(t)$	t	x_t	\tilde{x}_t	$\tilde{x}_t \cdot u(t)$	$\tilde{x}_t \cdot z(t)$
0	-0.45	-0.475	-0.475	0	10	-0.57	-1.504	0.7546	1.301
1	1.24	1.1241	0.5622	0.9734	11	0.98	-0.0449	-0.0224	0.0389
2	1.02	0.8132	-0.4063	0.7044	12	1.08	-0.0358	-0.0358	8E-05
3	0.39	0.0923	-0.0923	5E-05	13	3.28	2.0733	1.0413	1.7929
4	-0.55	-0.9386	0.4699	0.8125	14	2.18	0.8824	-0.4391	0.7654
5	-0.99	-1.4695	-0.7335	1.2733	15	1.12	-0.2685	0.2685	-8E-04
6	0.42	-0.1504	-0.1504	0.0002	16	0.58	-0.8994	0.4522	0.7775
7	1.72	1.0587	0.5306	0.9161	17	1.03	-0.5403	-0.2686	0.4688
8	2.47	1.7178	-0.8565	1.489	18	2.22	0.5588	0.5588	-0.002
9	0.58	-0.2631	0.2631	-5E-04	sum		1.7311	1.4213	11.31

فنجد ما يلي:

$$\hat{\beta} = \frac{2}{19} \sum_{t=0}^{18} \tilde{x}_t \cdot u(t) = \frac{2}{19}(1.4213) = 0.1496 > 0 \quad \& \quad \hat{\gamma} = \frac{2}{19} \sum_{t=0}^{18} \tilde{x}_t \cdot z(t) = \frac{2}{19}(11.31) = 1.1906 > 0$$

ومنهما نجد $\hat{\alpha} = 1.19996$ ، وبما أنّ $0 < \hat{\beta}$ و $0 < \hat{\gamma}$ فإنّ قيمة $\hat{\phi}$ نجدها باستخدام الجدول (١١، ١٢) تساوي:

$$\hat{\phi} = -\hat{\theta} = -\arctan \left| \frac{\hat{\gamma}}{\hat{\beta}} \right| = -1.4458$$

وبالتعويض في صيغة المركّبة $s(t)$ يكون لدينا:

$$\hat{s}(t) = \hat{m} + \hat{\alpha} \cos (\omega t + \hat{\phi}) = 0.0911 + 1.19998 \cos \left(\frac{\pi}{3}t - 1.4458 \right)$$


وبالتعويض في صيغة المتسلسلة الزمنية يتج لدينا أنَّ الطوري العشوائي المقدّر للطوري العشوائي المولّد للمتسلسلة الزمنية هو:

$$\hat{X}_t = \hat{\mathbf{m}}(t) + \hat{\mathbf{s}}(t) + N_t = 0.1161 + 0.0909t + 1.19998 \cos\left(\frac{\pi}{3}t - 1.4458\right) + N_t$$

انظر الشكل الآتي (١٧, ١٢. ب) لمقارنة بيان الدالة $y(t) = \mathbf{m}(t) + \mathbf{s}(t)$ مع بيان الدالة المقدّرة لها:

$$\hat{y}(t) = \hat{\mathbf{m}}(t) + \hat{\mathbf{s}}(t) = 0.1161 + 0.0909t + 1.19998 \cos\left(\frac{\pi}{3}t - 1.4458\right) \quad (*)$$

حيث نلاحظ جودة هذه الطريقة في عملية التقدير.




الشكل (١٧, ١٢. أ)

بعد إضافة المركبة العشوائية إلى العلاقة السابقة (*) نحصل على العرض الآتي لأحد مسارات الطوري العشوائي $\{X_t; t \geq 0\}$ ، وأما العرض الذي يليه فإنه يقدّم عرضاً نسبياً لمساري الطورين العشوائيين $\{X_t; t \geq 0\}$ ومقدّره $\{\hat{X}_t; t \geq 0\}$.



الشكل (١٧, ١٢. ب)



الشكل (١٧, ١٢. ج)

(١٢, ٤, ٢) اختبار جودة التوفيق للمركبة الدورية المقدرة بواسطة طريقة جيب التمام لـ هلبيرغ

Test for Goodness of Fit for the Period Component

فيما يلي نقدم اختباراً يبين لنا إن كان توفيق تقدير المركبة الدورية الناتجة عن طريقة جيب التمام لـ هلبيرغ مقبولاً أم لا. بالطبع يُشترط هنا أيضاً أن تكون أطوال الأدوار للمتسلسلة الزمنية متساوية، أي إن جميع الأدوار لهذه المتسلسلة الزمنية تملك العدد نفسه من المشاهدات (أو البيانات). عندئذ بفرض أن الدالة المقدرة هي:

$$\hat{y}(t) = \hat{m}(t) + \hat{s}(t) \quad [12,10]$$

وأن البيانات الناتجة عن هذه الدالة هي $\hat{y}_1, \hat{y}_2, \dots, \hat{y}_\tau$ من أجل $t = 1, 2, \dots, \tau$ على الترتيب، فإن هذه الطريقة تقوم على تنفيذ الخطوات الآتية:

١- نقوم بوضع البيانات المقدرة $\hat{y}_1, \hat{y}_2, \dots, \hat{y}_\tau$ في جدول بترتيب مصفوفي بحيث يوضع في العمود الأول القيم المقدرة المتتالية في الدور الأول، ومن ثم يوضع في العمود الثاني القيم المقدرة المتتالية في الدور الثاني، وهكذا دواليك، فنحصل على العرض الجدولي الآتي:

الجدول (١٣, ١٢)

		الأدوار			
		1	2	...	k
المشاهدة ضمن الدور لواحد	1	\hat{y}_{11}	\hat{y}_{12}	...	\hat{y}_{1k}
	2	\hat{y}_{21}	\hat{y}_{22}	...	\hat{y}_{2k}
	⋮	⋮	⋮	⋮	⋮
	p	\hat{y}_{p1}	\hat{y}_{p2}	...	\hat{y}_{pk}

علماً أن p هو طول الدور، و k هو عدد الأدوار التي لدينا في العينة، وفي حال كان لدينا بيانات غير كافية لشغل العمود الأخير (عدد أقل من p قيمة) فإننا نتجاهل استخدام تلك البيانات الأخيرة.

٢- نقوم باختبار الفرضية الابتدائية الآتية عند مستوى من الأهمية قدره α :

H_0 : النموذج المقدّر للمركبة الدورية (الموسمية) مناسب

مقابل الفرضية البديلة:

H_A : النموذج المقدّر للمركبة الدورية (الموسمية) غير مناسب

ومن أجل اتخاذ القرار الخاص بهذا الاختبار نقوم بما يلي:

أ- نحسب المتوسط لكل صف من صفوف الجدول السابق (١٣, ١٢) بواسطة العلاقة الآتية:

$$\bar{\hat{y}}_i = \frac{1}{k} \sum_{j=1}^k \hat{y}_{ij} \quad ; i = 1, 2, \dots, p$$

ب- نقوم بحساب صيغ التباينات الآتية:

$$SSD = \sum_{t=1}^{\tau} (x_t - \hat{y}_t)^2 \quad \& \quad SSE = \sum_{i=1}^p \sum_{j=1}^k \left(\hat{y}_{ij} - \bar{\hat{y}}_i \right)^2 \quad [12,11]$$

ج- نعرف إحصاءة F من خلال العلاقة الآتية:

$$F := \frac{(n - p)(SSD - SSE)}{(p - 3)SSE} \quad [12,12]$$

د- نقارن قيمة الإحصاءة F مع القيمة الجدولية $f_{1-\alpha}^{[p-3;n-p]}$ التي تستخرج من جدول توزيع فيشر.

هـ - **اتخاذ القرار:** إذا وجدنا أنَّ $f_{1-\alpha}^{[p-3;n-p]} < F$ ، فعندئذُ تُرفض الفرضية الابتدائية H_0 عند مستوى الأهمية α ونقبل الفرضية البديلة H_A ، وفي حال $f_{1-\alpha}^{[p-3;n-p]} \geq F$ فإنَّنا نقبل بالفرضية الابتدائية H_0 عند مستوى الأهمية α .

(١, ٢, ٤, ١٢) مثال

بالعودة إلى المثال (١, ١, ٤, ١٢) حيث قمنا بتقدير المركبة الدورية للمتسلسلة الزمنية المؤكدة بالطوري العشوائي $\{X_t; t \geq 0\}$ المعطى بالعلاقة الآتية:

$$X_t = 0.1 t + \sin(2\pi / 6)t + N_t \quad ; t \geq 0$$

ولنبين إن كان نموذج جيب التمام لـ هلبِرخ المُقدَّر للمركبة الدورية (الموسميّة) في ذلك المثال هو نموذج مناسب أم لا، وذلك عند مستوى من الأهمية $\alpha = 0.05$ ؟

من أجل ذلك علينا اختبار الفرضية الابتدائية الآتية عند مستوى الأهمية $\alpha = 0.05$:

H_0 : النموذج المقدَّر للمركبة الدورية (الموسميّة) مناسب :

مقابل الفرضية البديلة:

H_A : النموذج المقدَّر للمركبة الدورية (الموسميّة) غير مناسب :

حيث نعلم أنَّه لدينا ثلاثة أدوار في العينة المقدَّمة، وقيمها المقدَّرة وفقاً للدالة:

$$\hat{y}(t) = \hat{m}(t) + \hat{s}(t) = 0.1161 + 0.0909 t + 1.19998 \cos\left(\frac{\pi}{3}t - 1.4458\right)$$

يقدِّمها لنا الجدول الآتي:

الجدول (١٤, ١٢)

		Periods الأدوار			sum	$\bar{\hat{y}}_i$
		1	2	3		
$\bar{\hat{y}}_i$ القيم المقدَّرة المتتالية في كل دور	1	0.266	0.81	1.354	2.43	0.81
	2	1.313	1.858	2.403	5.57	1.858
	3	1.254	1.801	2.347	5.4	1.801
	4	0.24	0.787	1.334	2.36	0.787
	5	-0.626	-0.08	0.466	-0.2	-0.08
	6	-0.386	0.158	0.703	0.48	0.158

وبتنفيذ الحسابات المطلوبة لـ SSD و SSE نجد باستخدام العلاقتين [12,11] أنَّ:

$$SSD = 3.6846 \quad \& \quad SSE = 3.5709$$

ومن ثَمَّ يكون لدينا بحسب العلاقة [12,12]:

$$F = \frac{(18-6)(3.6846-3.5709)}{(6-3) 3.5709} = \frac{1.3644}{6.5709} = 0.208$$

ومن جدول توزيع فيشر نجد أنَّ $f_{0.95}^{[3;12]} = f_{1-\alpha}^{[p-3;n-p]} = 3.49$ ، وهكذا يكون لدينا:

$$f_{0.95}^{[3;12]} = 3.49 > F = 0.208$$

ولذلك علينا القبول بالفرضية الابتدائية عند مستوى الأهمية $\alpha = 0.05$.

في الواقع إنَّ النموذج الذي قمنا بتقديره للمركبة الدورية للمتسلسلة الزمنية في هذا المثال هو نموذج مناسب جداً لتلك المركبة ويتّضح ذلك بجلاء من خلال أخذ قيمة كبيرة لـ α كأن نأخذ على سبيل المثال $\alpha = 0.10$ ، فنجد رغم ذلك أنَّ قيمة الإحصاء F أصغر من القيمة الجدولية حيث لدينا:


$$f_{1-\alpha}^{[p-3; n-p]} = f_{0.90}^{[3; 12]} = 2.61$$

الآن وبعد التّحقّق من أنَّ النموذج الذي توصلنا إليه مناسب، فإنّه يمكننا توليد تنبؤات من هذا النموذج (وكما ذكرنا سابقاً على ألا يكون لأكثر من طول دور واحد)، فنجد على سبيل المثال قيم التنبؤات حتى طول دور كامل هي:

الجدول (١٢، ١٥)

Lag	19	20	21	22	23	24
x_t	2.95	2.89	1.88	1.01	1.25	2.45

ولعرضها البياني الشكل الآتي:




الشكل (١٢، ١٨). أ

فلاحظ أنَّ هذه التنبؤات مقبولة إلى حدٍّ ما بالمقارنة مع سلوك هذه العيّنة من مسار المتسلسلة الزمنية التي هي قيد الدراسة.

العرض الآتي (الشكل (١٢، ١٨). ب)) يقدّم لنا التوفيق (القيم المقدّرة) لبيانات هذه العيّنة مع التنبؤات لدور كامل باستخدام برنامج Minitab وذلك وفقاً لطريقة التجزئة (نموذج الجمع)، حيث يظهر لنا الاتجاه العام في هذه اللوحة أيضاً، وكذلك نلاحظ أنَّ قيم التنبؤات التي قدّمها هذا البرنامج تُعدّ أكثر منطقية من تلك التي قدمناها وفقاً لطريقة جيب التمام لـ هلبيرغ.


Forecasts	
Period	Forecast
20	3.72693
21	3.54932
22	2.09963
23	1.34243
24	1.89274
25	2.69763

علماً أنَّ **Period** تعني هنا ترتيب القيمة أو الفجوة الزمنية التي أُخذَ عندها التنبؤ حيث لدينا 19 قيمة سابقة (عدد البيانات الأصل لهذه العيّنة).



الشكل (١٨، ١٢. ب)

أما لإظهار فترة الثقة التي نوهنا عنها سابقاً فإننا سنستخدم طريقة وينتر Winters' Method (إحدى طرائق التنعيم للمتسلسلات الزمنية) في برنامج Minitab لتوليد التنبؤات، وذلك لأن هذه الطريقة من الطرائق الجيدة والمناسبة لدراسة مثل هذا النوع من المتسلسلات الزمنية، وكذلك تقدّم هذه الطريقة لنا فترة الثقة للتنبؤات. بعد تحميل طول الدور والتعديل على الأوزان α ، γ و δ بحيث نحصل على أصغر خطأ معياري للتقدير MSD، فإننا سنحصل على العرض الآتي الذي يتضمّن 95% فترة ثقة للتنبؤات المولدة.



الشكل (١٨، ١٢. ج)

إنّ استخدام هذه الطريقة يتطلب خبرة في كيفية تغيير قيم الأوزان α ، γ و δ الخاصّة بهذه الطريقة، وسوف نقدّم شرحاً موجزاً حول هذه الطريقة في نهاية هذا الفصل.

(١٢,٥) تنعيم المتسلسلات الزمنية

Smoothing of Time Series

قد تصادفنا حالات يكون فيها الاهتمام منصباً على المنحى الذي تتخذه المتسلسلة الزمنية وليس على التذبذبات (سواء كانت دورية أو موسمية) الحاصلة في مسار هذه المتسلسلة الزمنية. في مثل هذه الحالات يقوم المرء بمحاولة التخلص من هذه التذبذبات من خلال ما يُعرف باسم **تنعيم المتسلسلة الزمنية** التي تؤدي بالنتيجة إلى متسلسلة أخرى ذات تذبذبات بمطالات صغيرة بالمقارنة مع تذبذبات المتسلسلة الزمنية الأصل، ولكن لكي نشرح هذه الطريقة سنحتاج إلى تقديم بعض المفاهيم التي سندرجها من خلال التعاريف الآتية.

(١٢,٥,١) تعريف (معامل الخشونة Roughness Coefficient)

لتكن لدينا $x_1, x_2, \dots, x_{\tau}$ بيانات متسلسلة زمنية. عندئذ يُعرف معامل الخشونة لهذه المتسلسلة الزمنية بوساطة العلاقة الآتية:

$$RC := \sum_{t=2}^{\tau} (x_t - x_{t-1})^2 \bigg/ \sum_{t=2}^{\tau} (x_t - \bar{x})^2$$
 [12,13]

لاحظ أنَّ هذه العلاقة هي نسبة متوسط مربع انحرافات القيم المتتالية للبيانات إلى تباين البيانات (حول متوسطها)، ومن ثمَّ قيمة هذا المعامل يزداد كبراً كلما كُبر الفرق بين القيم المتتالية وصَغُرَ بين القيم ومتوسطها.


(١٢,٥,١,١) مثال

لتكن لدينا البيانات الآتية لعينة مأخوذة من مسار متسلسلة زمنية:

الجدول (١٢,١٦)

t	1	2	3	4	5	6	7	8	9	10
x_t	63	101	84	116	110	137	100	94	129	98

والتي لبصمتها العرض الآتي:



شكل (١٢,١٩).

ف نجد أنَّ متوسط البيانات المُعطاة يساوي $\bar{x} = 103.2$ ، ومن ثمَّ بحسب العلاقة [12,13] تكون قيمة مُعامل الخشونة لهذه المتسلسلة الزمنية يساوي:

$$RC = 7113 \times (2513.56)^{-1} = 2.83$$

(١٢, ٥, ٢) التنعيم باستخدام المتوسطات المتحركة Smoothing by Moving Averages

في الواقع يمكن تنعيم مسار متسلسلة زمنية تعاني من خشونة كبيرة بوساطة ما يسمّى بالمتوسطات المتحركة ذات الطول k التي تقدّمها لنا الفقرة الآتية.

(١٢, ٥, ٢, ١) تعريف المتوسط المتحرك بطول k

لتكن لدينا x_1, x_2, \dots, x_τ بيانات مُعطاة، و $k \in \mathbb{N}$ عدد مُعطى. عندئذ يُعرّف المتوسط المتحرك بطول k لهذه البيانات بوساطة العلاقة الآتية:

$$\bar{x}_{k,t} := \frac{x_t + x_{t+1} + \dots + x_{t-k+1}}{k} \quad ; k = 1, 2, 3, \dots, \tau - (k - 1) \quad [12,14]$$

(١٢, ٥, ٢, ٢) ملاحظات

١- إنّ البيانات الناتجة عن قيم المتوسطات المتحركة بطول k لمتسلسلة زمنية تُعطينا بدورها متسلسلة زمنية جديدة ولكن بمُعامل خشونة أقل (على الغالب) من معامل الخشونة للمتسلسلة الزمنية الأصل، ولهذا السبب ستكون المتسلسلة الزمنية المؤكدة بمتوسطات متحركة أكثر نعومةً من المتسلسلة الزمنية الأصل على الغالب، ولذلك تستخدم طريقة المتوسطات المتحركة كإحدى الطرائق لتنعيم المتسلسلات الزمنية، وفي حال اللجوء إلى هذه الطريقة يُؤخذ عادة طول الدور (أو عدد المواسم في العام) كطول للمتوسط المتحرك الذي سيستخدم.

٢- إذا كان طول المتوسط المتحرك المستخدم k ، فعندئذ سينقص عدد البيانات الناتجة عن استخدام هذا المتوسط المتحرك بمقدار $\tau - (k - 1)$ ، ولتوضيح الملاحظتين السابقتين سنأخذ المثال الآتي.


(١٢, ٥, ٢, ٣) مثال

لتكن لدينا عينة مأخوذة من مسار متسلسلة زمنية مُعطاة كما في الجدول الآتي:


الجدول (١٧, ١٢. أ)

t	1	2	3	4	5	6	7	8	9	10	11	12	13
x_t	11	18	16	28	25	35	40	35	25	28	16	18	11

والتي لبصمتها الشكل (١٢, ٢٠. أ).



الشكل (١٢, ٢٠. ب)



الشكل (١٢, ٢٠. أ)

ومن أجل حساب معامل الخشونة لهذه المتسلسلة الزمنية لنبنى الجدول الآتي:

الجدول (١٧, ١٢. ب)

t	x_t	$(x_t - x_{t-1})^2$	$(x_t - \bar{x})^2$
1	11		
2	18	49	30.6916
3	16	4	56.8516
4	28	144	19.8916
5	25	9	2.1316
6	35	100	131.3316
7	40	25	270.9316
8	35	25	131.3316
9	25	100	2.1316
10	28	9	19.8916
11	16	144	56.8516
12	18	4	30.6916
13	11	49	157.2516
sum	306	662	909.9792

ف نجد أنَّ قيمة متوسط البيانات الأصل $\bar{x} = 23.53846$ ، ومن ثمَّ بحسب العلاقة [12,13] يكون لدينا $RC = \frac{662}{909.979} = 0.727$ ، ولنقم بتوليد متسلسلة زمنية من المتسلسلة الزمنية السابقة باستخدام متوسط متحرك بطول 3 فنجد بياناتها كما في الجدول الآتي:

الجدول (١٨, ١٢)

t	x_t	$(x_t - x_{t-1})^2$	$(x_t - \bar{x})^2$
1	-----	-----	-----
2	15	-----	-----
3	20.66667	32.11111	22.30988
4	23	5.444444	5.7121
5	29.33333	40.11111	15.54988
6	33.33333	16	63.09654
7	36.66667	11.11111	127.1632
8	33.33333	11.11111	63.09654
9	29.33333	16	15.54988
10	23	40.11111	5.7121
11	20.66667	5.444444	22.30988
12	15	32.11111	107.9521
13	-----	-----	-----
sum	279.3333	209.5556	448.4521

ف نجد أنَّ قيمة متوسط البيانات الأصل $\bar{x} = 25.394$ ، وبحسب العلاقة [12,13] يكون معامل الخشونة لهذه المتسلسلة الزمنية يساوي $RC = 0.467$ ، والشكل السابق (١٢, ٢٠. ب) يعرض لنا بصمة المتسلسلة الزمنية المؤكدة بالمتوسط المتحرك ذي الطول 3 (لاحظ النعومة التي طرأت على مسارها).

لاحظ أنَّه لتبسيط العمليات الحسابية فإنَّه عند تشكيل المتسلسلة الزمنية المؤكدة بمتوسط متحرك نقوم بترتيب قيمها بحيث يكون عدد الفراغات (الناجمة عن النقص في عدد المشاهدات) في الأعلى يساوي عدد الفراغات التي في الأسفل إذا كان طول المتوسط المتحرك k عدداً فردياً، وأما إذا كان k عدداً زوجياً فعندئذ نجعل الفراغات في الأعلى أقل من الفراغات التي في الأسفل بمقدار فجوة زمنية واحدة. بالطبع هناك الكثير من الدراسات التي تتعلَّق بالمركِّبات الدورية للمتسلسلات الزمنية ولكننا سنكتفي بهذا القدر من الدراسة، ويمكن لمن يودُّ الاطلاع على المزيد الرجوع إلى المراجع ذات الصلة ومنها في فهرس المراجع في نهاية هذا الكتاب.

(١٢,٦) دراسة التغيرات الموسمية لمتسلسلة زمنية**Study of the Seasonal Changes of a Time Series**

لقد ذكرنا سابقاً أنَّ التغيرات الموسمية (التي تمثلها المركبة الموسمية) لمتسلسلة زمنية هي تغيرات متشابهة ذات تكرار منتظم على مدى فترة من الزمن (تُدعى طول الفترة -أو الدورة- الموسمية)، وهنا نودُّ أن نشير إلى أنَّ كلمة موسمية قد تأخذ دلالات مختلفة للوصف السابق، فعلى سبيل المثال لا الحصر:

١- من الممكن أن تحدث التغيرات الموسمية كل يوم مثل قيم درجات الحرارة منتصف النهار إذا كانت البيانات المقدمة هي قياس درجة الحرارة خلال كل ساعة.

٢- من الممكن أن تحدث التغيرات الموسمية كل أسبوع مثل عدد السيارات التي تسير على الطريق الدائري الشرقي في الرياض يوم الجمعة من الساعة السابعة وحتى التاسعة صباحاً إذا كانت البيانات المقدمة هو عدد السيارات المارة على هذا الطريق في هذه الفترة الزمنية من كل يوم.

٣- من الممكن أن تحدث التغيرات الموسمية في أوقات مُحددة من العام مثل مبيعات متجر ملابس إذا كانت البيانات المقدمة هي قيمة المبيعات كل أسبوع، فحينئذ يلاحظ أنَّ الأسبوع الذي يسبق كل عيد (عيد الفطر والأضحى) يبدي تغيراً موسمياً (بطول فترة موسمية غير ثابت).

في الحقيقة لوحظ أنَّ المتسلسلات الزمنية في القطاعين الاقتصادي والاجتماعي يكون لها تغيرات موسمية بمواسم شهرية (إذا كانت البيانات المقدمة مأخوذة كقياسات يومية) أو ربع سنوية (إذا كانت البيانات المقدمة مأخوذة كقياسات يومية أو أسبوعية)، ويعود ذلك إلى أسباب تؤثر في قيم هذه القياسات من أهمها العادات والتقاليد الاجتماعية والطقس أيضاً. أما المتسلسلات الزمنية في القطاعين الطبي والنفسي فيكون لها تغيرات موسمية بمواسم قد تبدأ بـ ثوان (مثل البيانات التي تستخدم لرسم مخطط الرسم الكهربائي للقلب) ومن الممكن أن تمتد إلى أشهر وسنوات مثل البيانات التي تمثل تطور حالة مريض نفسي.

في الواقع يصعب (لا بل من الصعب جداً) تحديد تأثير التغيرات الموسمية دون الانتباه إلى الاتجاه العام للمتسلسلة الزمنية، ولذلك يُنصح بإزالة الاتجاه العام للمتسلسلة الزمنية أولاً، ومن ثمَّ البحث في دراسة الأثر الموسمي.

إنَّ دراسة التغيرات الموسمية للمتسلسلات الزمنية زاهر بالطرائق المستخدمة لأجله، ولكل طريقة هدف قد يختلف عن هدف الطريقة الأخرى، فمنها يستخدم للتخلص من الأثر الموسمي (التخلص من المركبة الموسمية) أو التقليل من شأنه، وبعضها الآخر يقوم على تقدير الأثر الموسمي. هذا من جانب، ومن جانب آخر هناك تباين كبير في صعوبة دراسة الأثر الموسمي وفقاً للهدف والنموذج الذي يخضع للدراسة، فمنها يتطلب التعامل مع منظومة معادلات رياضية قد لا تكون بسيطة كما هو الحال في نماذج الانحدار الذاتي والمتوسطات المتحركة التكاملية ARIMA، ومنها ما هو بسيط نسبياً كتلك الطرائق التي تدرس المركبة الموسمية بأسلوب تقليدي، ومن هذه الطرائق:

أ- طريقة المتوسطات المتحركة.

ب- طريقة التعديل الذاتي.

ج- طريقة تحديد التغيرات الموسمية.

د- طريقة إيجاد التقلبات الموسمية بدلالة الوحدات المطلقة.

فيما يلي سنكتفي بشرح طريقة النسبة إلى متوسط متحرك في دراسة المركبة الموسمية ومن يودُّ الاطلاع على المزيد يمكنه الرجوع إلى المراجع ذات الصلة.

(١, ٦, ١٢) طريقة النسبة إلى متوسط متحرك Ratio to Moving-Average Method

لقد لاحظنا أنَّ طريقة المتوسطات المتحركة مفيدة في تنعيم المتسلسلة الزمنية والتخلص من الاهتزازات المكوَّنة للمركَّبة الدورية عندما يكون اهتمامنا منصَّباً على الاتجاه العام للمتسلسلة الزمنية، ولكنَّ هذه الطريقة مفيدة في مجال تحليل التغيُّرات الموسميَّة أيضاً، وتعتمد في تحليلها للتغيُّرات الموسميَّة على الخطوات الآتية:

١- جعل مسار المتسلسلة الزمنية أملساً بالقدر المستطاع من خلال أخذ متوسط متحرك مناسب، ويؤخذ في هذه الحالة طول المتوسط المتحرك يساوي عدد الفصول في العام، مع العلم أنَّ كلمة فصل هنا قد لا تعني بالضرورة ثلاثة أشهر كما هو دارج، وإنَّما يعني فترة من السنة يتفق عليها من أجل أخذ القياسات (القيم المشاهدة).

٢- إيجاد حاصل ضرب المركَّبة الموسميَّة مع المركَّبة العشوائية وذلك من خلال قسمة البيانات الأصلية للمتسلسلة الزمنية على المتوسط المتحرك المقابل لتلك القيم، ومن ثمَّ ضرب الناتج بـ 100.

٣- عزل المركَّبة الموسميَّة عن المركَّبة العشوائية، وذلك بالتعديل على السنوات من خلال جعل القيم الناتجة في الخطوة السابقة لكلِّ موسم بعضها فوق بعض لكل السنوات.

٤- حساب المتوسط لقيم الموسم (أو فصل) k للبيانات الناتجة في البند الثاني، حيث سنرمز لهذا المتوسط بـ \bar{x}_k و k تأخذ قيمها بعدد المواسم المتاحة للدراسة.

٥- حساب ما يُعرف باسم **المجموع الأصلي للنسب المئوية**، وهو عدد المواسم (أو الفصول) مضروب بـ 100، وسنرمز له بـ α .

٦- حساب المجموع لكلِّ هذه المتوسطات \bar{x}_k (المحسوبة في الخطوة الرابعة) الأخيرة وسنفترضه يساوي β .

٧- تقدير المركَّبة الموسميَّة ذات الرقم i (وسنرمز لها بـ \hat{s}_i) من خلال ضرب قيمة المتوسط للموسم (أو الفصل) في القيمة $\gamma = \alpha / \beta$.

(١, ٦, ١٢) مثال


لتكن لدينا البيانات الآتية لعينة مأخوذة من مسار متسلسلة زمنية لمصاريف شركة تجارية على العمال في نهاية كل شهرين (مقدَّرةً بـ 1000 وحدة نقدية)، أي إنَّه لدينا ستة فصول أو مواسم (طول كل فصل يساوي شهرين) في هذه المتسلسلة الزمنية.

الجدول (١٩, ١٢, أ)

العام	t	الموسم Season	المصاريف Outlay
2010	1	1	155
	2	2	95
	3	3	236
	4	4	163
	5	5	250
	6	6	588
2011	7	1	41
	8	2	41
	9	3	71
	10	4	94
	11	5	157
	12	6	751

العام	t	الموسم Season	المصاريف Outlay
2012	13	1	155
	14	2	250
	15	3	119
	16	4	216
	17	5	229
	18	6	1061
2013	19	1	66
	20	2	95
	21	3	131
	22	4	232
	23	5	142
	24	6	783

والتي لبصمتها العرض الآتي:



الشكل (٢٠، ١٢. ب)


ولنقم بتقدير المركبات الموسمية لهذه المتسلسلة الزمنية وفقاً لطريقة النسبة إلى متوسط متحرك.

من أجل تحقيق البند الأول سنقوم بتنعيم المتسلسلة الزمنية التي لدينا باستخدام متوسط متحرك بطول يساوي 6 (لأنه لدينا ست مشاهدات في كل عام) فنحصل على المتسلسلة الزمنية المنعّمة الآتية:

الجدول (١٩، ١٢. ب)


t	1	2	3	4	5	6	7
$\bar{x}_{6,t}$	-----	-----	247.83	228.83	219.83	192.33	180.83
t	8	9	10	11	12	13	14
$\bar{x}_{6,t}$	165.33	192.5	211.5	246.33	254.33	274.67	286.67
t	15	16	17	18	19	20	21
$\bar{x}_{6,t}$	338.33	323.5	297.67	299.67	302.33	287.83	241.5

والتي لبصمتها الشكل الآتي:



الشكل (٢٠، ١٢. ج)

ووضعها النسبي مع المتسلسلة الزمنية الأصل يقدمها الشكل الآتي:



الشكل (٢٠، ١٢. د)

لاحظ كيف أصبح مسار المتسلسلة الزمنية الناتجة عن المتوسطات المتحركة ناعماً جداً بالمقارنة مع مسار المتسلسلة الزمنية الأصل.

الآن لتطبيق الخطوة الثانية من هذه الطريقة نقوم ببناء الجدول الآتي حيث نجد فيه نواتج حاصل ضرب المركبة الموسمية مع المركبة العشوائية التي تنتج من خلال قسمة البيانات الأصلية للمتسلسلة الزمنية على المتوسط المتحرك المقابل لتلك القيم، ومن ثم ضرب الناتج بـ 100.

الجدول (١٩، ١٢ ج)

t	1	2	3	4	5	6	7
$(x_t / \bar{x}_{6,t}) \times 100$	-----	-----	95.2	71.23	114	305.7	22.67
t	8	9	10	11	12	13	14
$(x_t / \bar{x}_{6,t}) \times 100$	24.8	36.88	44.44	63.7	295.3	56.4	87.21
t	15	16	17	18	19	20	21
$(x_t / \bar{x}_{6,t}) \times 100$	35.17	66.8	76.93	354.1	21.8	33.01	54.2

ولكي نعزل المركبة الموسمية عن المركبة العشوائية نقوم بالتعديل على السنوات من خلال جعل القيم الناتجة في الخطوة السابقة لكل موسم بعضها فوق بعض لكل السنوات، وناتج هذه العمليات يبينها الجدول الآتي:

الجدول (١٩، ١٢ د)

Year	الموسم الأول	الموسم الثاني	الموسم الثالث	الموسم الرابع	الموسم الخامس	الموسم السادس	
2010	-----	-----	95.23	71.23	113.7	305.7	
2011	22.67	24.8	36.88	44.44	63.73	295.3	
2012	56.43	87.21	35.17	66.77	76.93	354.1	
2013	21.83	33.01	54.24	-----	-----	-----	
mean	\bar{x}_1 33.65	\bar{x}_2 48.34	\bar{x}_3 55.38	\bar{x}_4 60.82	\bar{x}_5 84.8	\bar{x}_6 318.4	$\beta = \sum_{k=1}^6 \bar{x}_k = 601.3$


وبما أنه لدينا ستة فصول (وفقاً لهذا المثال) فإنه سيكون لدينا $\alpha = 6 \times 100 = 600$ ، ومن ثم نجد أن $\gamma = \frac{\alpha}{\beta} = \frac{600}{601.3} = 0.998$ وهكذا يكون لدينا مُقدِّرات المركبات الموسمية هي:

$$\begin{aligned} \hat{S}_1 &= \gamma \times 33.65 = 0.998 \times 33.65 = 33.583 \\ \hat{S}_2 &= \gamma \times 48.34 = 0.998 \times 48.34 = 48.243 \\ \hat{S}_3 &= \gamma \times 55.38 = 0.998 \times 55.38 = 55.269 \\ \hat{S}_4 &= \gamma \times 60.82 = 0.998 \times 60.82 = 60.698 \\ \hat{S}_5 &= \gamma \times 84.8 = 0.998 \times 84.8 = 84.630 \\ \hat{S}_6 &= \gamma \times 318.4 = 0.998 \times 318.4 = 317.763 \end{aligned}$$

بهذا نأتي على نهاية هذه الفقرة، ونقدّم فيما يلي إحدى الطرائق المستخدمة في توليد التنبؤات من بيانات متسلسلة زمنية.

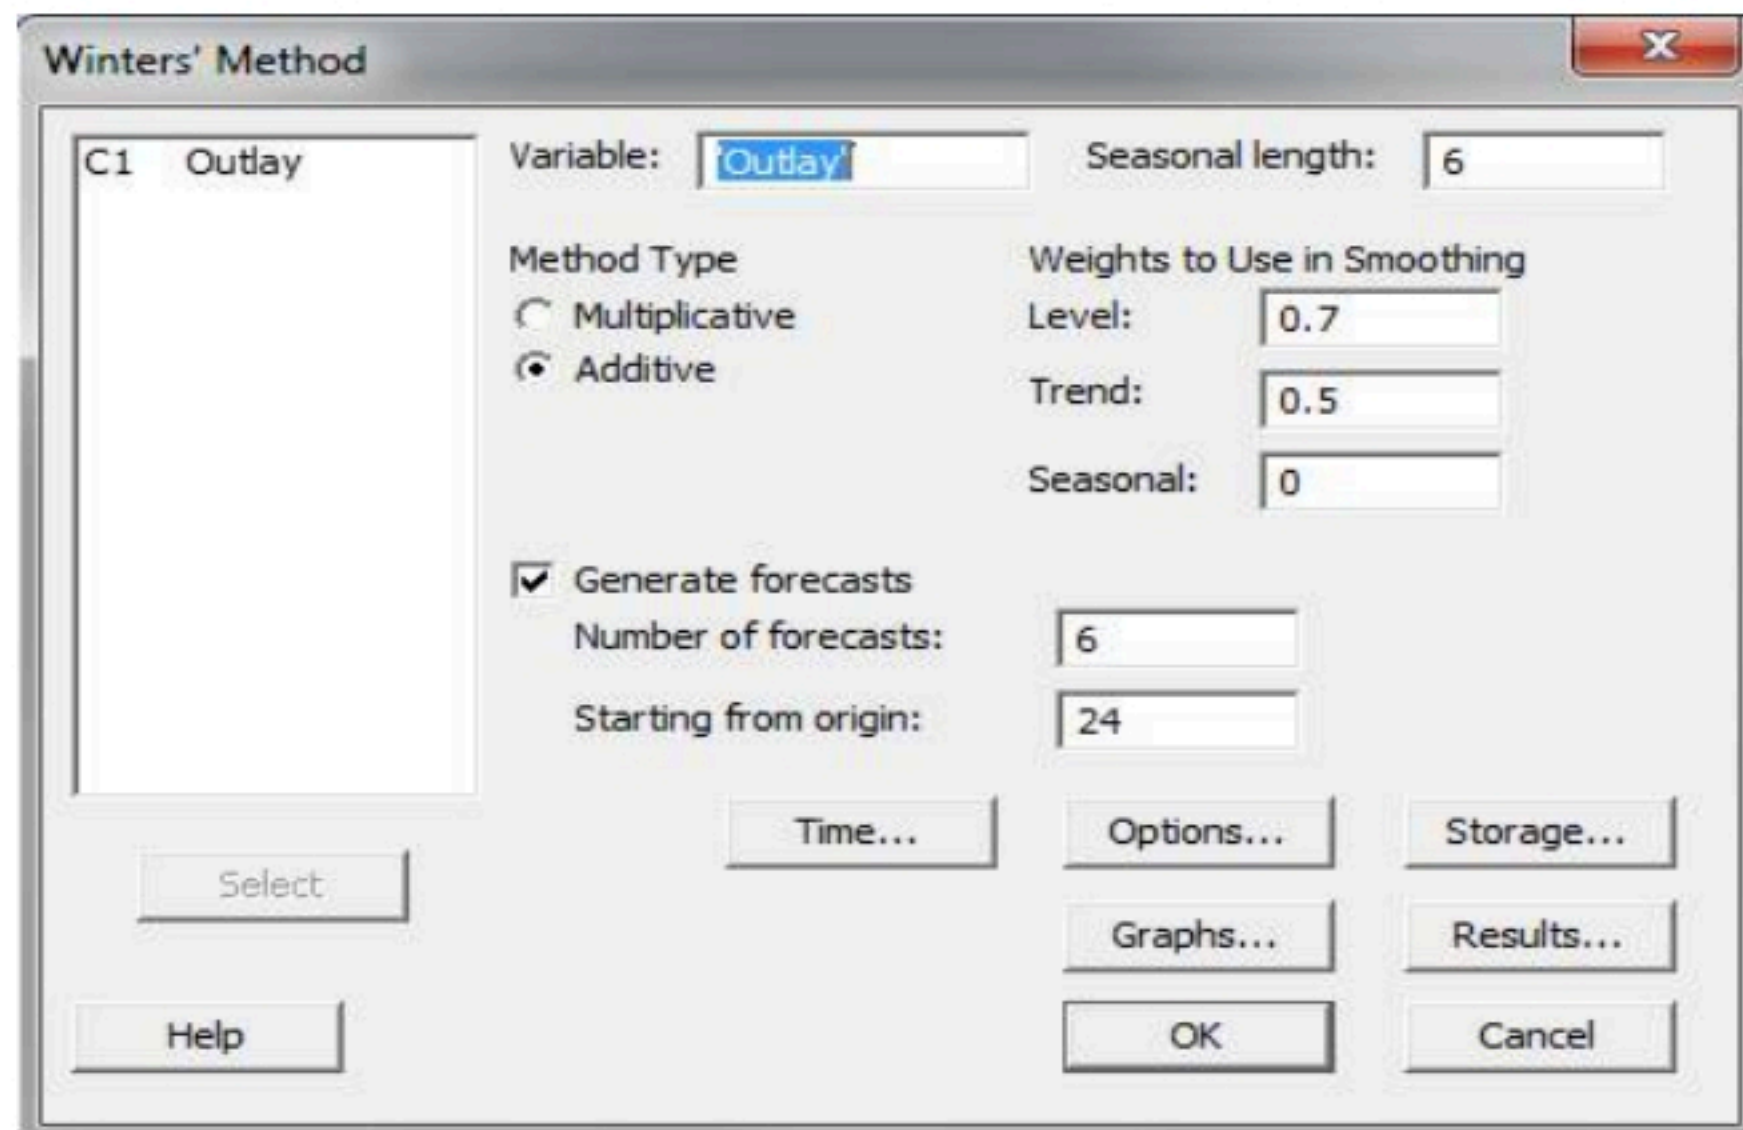
(١٢,٧) طريقة وينتر لتوليد تنبؤات من متسلسلة زمنية**Winter's Method for Generate Forecasts of a Time Series**

قبل أن نختم هذا الفصل سنقوم باستخدام طريقة وينتر لتوليد بعض التنبؤات للمتسلسلة الزمنية المعطاة في المثال السابق، وذلك باستخدام الخطوات الآتية:



Stat → Time Series → Winters' Method.


ومن ثم في نافذة Variable أدخل كلمة Outlay وفي نافذة Seasonal Length أدخل العدد 6، ومن أجل النموذج في Model Type نفعل Additive. أما الأوزان α و γ و δ فيمكن التعديل عليها بحيث نحصل على أصغر خطأ معياري MSD ممكن للتقدير (وكما ذكرنا سابقاً بأن هذه العملية تحتاج إلى خبرة وجهد للوصول إلى القيم المناسبة لهذه الأوزان)، ومن أجل مثالنا هذا اخترنا قيم الأوزان كما في التقرير الآتي الذي يقدم لنا 95% فترة ثقة للتنبؤات المؤكدة أيضاً، وذلك بعد تفعيل Generate forecasts وإدخال 6 في نافذة Number of forecasts، وكذلك 24 في نافذة Starting from origin، وأخيراً الضغط على أيقونة OK.



فنحصل على التقرير الآتي (سنضعه في جدول بعمودين مع أخذ ما الأمعطيات التي نحتاجها فقط):

Winters' Method for Outlay		Forecasts			
		Period	Forecast	Lower	Upper
Additive Method					
Data	Outlay				
Length	24	25	111.839	-110.318	334.00
Smoothing Constants		26	112.830	-142.182	367.84
α (level)	0.6	27	116.821	-178.102	411.74
γ (trend)	0.3	28	138.811	-200.597	478.22
δ (seasonal)	0.0	29	142.052	-244.843	528.95
Accuracy Measures		30	728.293	291.889	1164.70
MSD	17185.2				

والعرض البياني المرافق لهذا التقرير يقدمه الشكل الآتي:



الشكل (١٢, ٢٠) هـ

في الحقيقة إنّ طريقة وينتر تُعدّ من الطرائق الجيدة في توفيق الكثير من المسلسلات الزمنية، ولكن استخدامها يحتاج إلى خبرة وجهد، وفيما يلي نقدّم موجزاً حول هذه الطريقة.

(١٢, ٧, ١) طريقة وينتر في توفيق نموذج متسلسلة زمنية

إنّ طريقة وينتر تقوم على أساس تنعيم البيانات بوساطة التنعيم الأسّي لـ Holt-Winters الذي يزودنا بقليل من التنبؤ متوسط المدى، حيث يمكننا استعمال هذا الإجراء عندما يكون لدينا اتجاه عام ومركبة موسميّة (وكحالة خاصّة مركبة دوريّة) في المتسلسلة الزمنية.

من أجل التحليل باستخدام طريقة وينتر يجب اختيار أحد نموذجين منطلقين من معرفتنا المسبقة لطول دور الموسم p ، وهذين النموذجين (الممكن استخدام أحدهما في تنفيذ التحليل) هما:

١- نموذج الجمع Additive Model، وقد تحدثنا سابقاً عن كيفية استخدام هذا النموذج.

أمّا العلاقات المستخدمة وفقاً لهذا النموذج من أجل الحصول على التقديرات للبيانات التي قيد الدراسة (حيث طول دور الموسم p يجب أن يكون معلوماً)، فإنّها تتمّ بحساب المقادير الآتية أولاً:

$$L_t = \alpha(Y_t - S_{t-p}) + (1 - \alpha)(L_{t-1} + T_{t-1})$$

$$T_t = \gamma(L_t - L_{t-1}) + (1 - \gamma)T_{t-1}$$

$$S_t = \delta(Y_t - L_t) + (1 - \delta)S_{t-p}$$

علماً أنّ L_t هي قيمة المستوى (أو التمهيد) Level عند اللحظة الزمنية t ، و α هو ثابت ويمثّل الوزن للمستوى (أو الوزن للتمهيد) Weight for the level، و T_t هي قيمة الاتجاه العام Trend عند اللحظة الزمنية t ، و γ هو ثابت ويمثّل الوزن للاتجاه العام Weight for the trend، و S_t هي قيمة المركبة الموسميّة Seasonal عند اللحظة الزمنية t ، وأخيراً δ هو ثابت ويمثّل الوزن للمركبة الموسميّة Weight for the seasonal component.

عندئذ تحسب التقديرات \hat{x}_t وفقاً للعلاقة الآتية:

$$\hat{x}_t = L_{t-1} + T_{t-1} + S_{t-p}$$

علماً أنَّ \hat{x}_t هي قيمة التنبؤ المناسبة للوحدة الزمنية التالية للحظة الزمنية $t-1$ ، بمعنى أنه وفقاً لهذه الطريقة يتم التنبؤ فيها باستخدام التكرار التقدّمي للحصول على التنبؤات ولكن واحدة فواحدة فقط إلى حين الوصول إلى نهاية الفترة الزمنية المطلوب التنبؤ عنها.

٢- نموذج الضرب Multiplicative Model، وقد تحدثنا سابقاً عن كيفية استخدام هذا النموذج أيضاً، وأما العلاقات المستخدمة وفقاً لهذا النموذج من أجل الحصول على التقديرات للبيانات التي قيد الدراسة (تحت الفرض أنَّ طول دور الموسم p معلوماً)، فإنها تتم بحساب المقادير الآتية أولاً:

$$L_t = \alpha \left(\frac{Y_t}{S_{t-p}} \right) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad \& \quad T_t = \gamma (L_t - L_{t-1}) + (1 - \gamma)T_{t-1}$$

$$S_t = \delta \left(\frac{Y_t}{L_t} \right) + (1 - \delta)S_{t-p}$$

علماً أنَّ الرموز الواردة في هذه العلاقات لها الدلالات السابقة نفسها. عندئذ تحسب التقديرات \hat{x}_t وفقاً للعلاقة الآتية:

$$\hat{x}_t = (L_{t-1} + T_{t-1}) \cdot S_{t-p}$$

وهنا \hat{x}_t هي قيمة التنبؤ المناسبة للوحدة الزمنية التالية للحظة الزمنية $t-1$ أيضاً، بمعنى أنه وفقاً لهذه الطريقة يتم التنبؤ فيها باستخدام التكرار التقدّمي للحصول على التنبؤات، ولكن واحدة فواحدة فقط إلى حين الوصول إلى نهاية الفترة الزمنية المطلوب التنبؤ عنها.

عند اختيار أي من النموذجين السابقين فإن طريقة وينتر تقدّم لنا حسابات فعّالة للتقدير باستعمال معالم التنعيم الثلاثة: معلمة المستوى Level Parameter، معلمة الاتجاه العام Trend Parameter وأخيراً المعلمة الموسمية Seasonal Parameter، علماً أنَّ هذه المعالم تأخذ قيمها في الفترة $[0, 1]$.

إنّ برنامج Minitab ينطلق بتقدير متوازن لهذه المعالم عند القيمة 0.2، وعلى الباحث أن يقوم بالتعديل على هذه المعالم تجريبياً (أو حسب خبرته) للحصول على التقدير الدقيق المطلوب للمسألة التي قيد الدراسة، بمعنى أنه لا توجد قيم مثلى للمعالم الثلاثة السابقة (معلمة المستوى، معلمة الاتجاه العام، المعلمة الموسمي) وفقاً لطريقة وينتر بحيث يحصل المرء على التقديرات الأكثر دقة كما هو الحال لدى ما يُعرف باسم طريقة التنعيم الأسّي المفرد والمزدوج (التنعيم الأسّي المفرد والمزدوج من الطرائق التي يمكن إنجازها في برنامج Minitab أيضاً).

الآن وبعد الوصول إلى التعديل النهائي على قيم معالم المستوى، الاتجاه العام والموسمي يمكننا استخدام هذا النموذج للحصول على تقديرات جيدة للتنبؤات بعد تزويده بطول الموسم (طول الدور للحركة الاهتزازية الممثلة للمركبة الدورية والموسمية).

(١، ١، ٧، ١٢) توفيق النموذج Fitting of Model

إنّ طريقة وينتر تستثمر قيم المعالم الثلاثة (معلمة المستوى، معلمة الاتجاه العام، المعلمة الموسمي) في الحسابات ضمن كل دور من الأدوار الموجودة في مسار المتسلسلة الزمنية، وعلاوة على ذلك تستخدم هذه المعالم الثلاثة لتحسين وتطوير قيم المركبات الموافقة لها في كل دور من الأدوار. إنَّ القيم الأولية لمركبات الاتجاه العام والمستوى يُستحصل عليها من الانحدار الخطي مع مرور الزمن، وأما القيم الأولية للمركبة الموسمية فإنه يُستحصل عليها من استعمال متغيّر انحدار زائف (وهي) مستخدماً البيانات المقدّرة للاتجاه العام الناتجة عن الانحدار الخطي.

أما بالنسبة إلى جودة توفيق النموذج فإنه توجد معايير للحكم على مدى هذه الجودة، وهذا يعدّ من ضرورات الحصول على تنبؤات مقبولة ومنسجمة مع سلوك المتسلسلة الزمنية، وذلك لأنّ أغلب التنبؤات ومهما كانت طريقة التنبؤ تميل إلى أن تكون غير صحيحة مئة بالمئة، ولذلك لا بدّ من تقييم جودة التنبؤ بمقارنة القيم الحقيقية بالقيم المقدرة، وهذه المقارنة ستكشف لنا حجم الأخطاء في التنبؤ (ومن ثمّ تقييم جودة التنبؤ).

إنّ أغلب مقاييس جودة التوفيق تعتمد على قيم الانحرافات بين القيم الفعلية للمتسلسلة الزمنية الأصل والقيم المقدّرة لها، ومن المعايير المستخدمة في قياس جودة التوفيق Measuring Fitting Accuracy في برنامج Minitab هي:

١ - متوسط القيم المطلقة للانحرافات Mean Absolute Deviation، ويُعطى هذا المقياس بالعلاقة الآتية:

$$MAD = \sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{n}$$

٢ - متوسط القيم المطلقة للنسب المئوية للأخطاء (أو متوسط القيم المطلقة للنسب المئوية للانحرافات) Mean Absolute Percentage Error، ويعطى هذا المقياس بالعلاقة الآتية:

$$MAPE = \frac{100}{n} \sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{y_t}$$

٣ - متوسط مربع الانحرافات Mean Square Deviation (والذي اعتمدناه سابقاً)، ويعطى هذا المقياس بالعلاقة الآتية:

$$MSD = \sum_{t=1}^n \frac{(y_t - \hat{y}_t)^2}{n}$$

علماً أنّ y_t هي قيمة المشاهدة التي رُصدت عند اللحظة الزمنية t ، وأما \hat{y}_t فهي القيمة المقدّرة لـ y_t عند اللحظة الزمنية t وفقاً للنموذج المعتمد في التوفيق، وأخيراً n هو عدد المشاهدات (أو حجم العيّنة) من مسار المتسلسلة الزمنية التي أخضعت للدراسة.

(١٢,٧, ١, ٢) التنبؤ Forecasting

تستعمل طريقة وينتر كل من المستوى، والاتجاه العام والمركّبات الموسميّة لتوليد التنبؤات. إنّ التنبؤ لـ k لحظة زمنية قادمة بدءاً من لحظة زمنية مفترضة t يقوم البرنامج بحساب $L_t + k \cdot T_t$ ، ومن ثمّ يجمع (أو يضرب من أجل النموذج الضريبي) هذه المركّبة مع (أو يضرب بـ) المركّبة الموسميّة وذلك من أجل الدور نفسه من الدورة السابقة Previous Cycle. علاوةً على ذلك تستخدم طريقة وينتر البيانات من لحظة البدء المفترضة لتوليد التنبؤات المطلوبة.

(١٢,٧, ١, ٣) اختيار الأوزان وفقاً لطريقة وينتر

يمكنك إدخال الوزن أو معلمة التنعيم للمستوى وللاتجاه العام والمركّبات الموسميّة. إنّ الأوزان الافتراضية كما ذكرنا سابقاً هي 0.2، ولكن يمكننا إدخال أي قيمة تقع بين 0 والـ 1 حسبما تقتضي الحاجة لتحسين دقة نتائج النموذج. إلّا أنّه بغض النظر عن المركّبات فإنّ الأوزان الكبيرة تُؤدّي إلى تغييرات أكثر سرعة في المركّبات، في حين أنّ الأوزان الصغيرة تؤدي إلى تغييرات أقل سرعة. إنّ المركّبات تؤثر تباعاً في القيم المنعّمة (أو المقدّرة) والمُتنبأ بها أيضاً، ولهذا فإنّه يوصى عادة باستخدام أوزان صغيرة من أجل المتسلسلات الزمنية ذات مستوى ضوضاء عال حول الإشارة أو الشكل، وأما الأوزان الكبيرة فإنّه يوصى بها عادةً من أجل المتسلسلات الزمنية ذات مستوى ضوضاء منخفض حول الإشارة أو الشكل.

هذا ما تيسّر تقديمه من أجل الجزء النظري والتطبيقي لهذا الفصل

تمارين الفصل الثاني عشر

- ١- تحدث عن الأسباب التي تدفعنا لتحليل متسلسلة زمنية.
- ٢- تحت الفرض أننا قمنا بتحليل متسلسلة زمنية وقمنا بتعيين نموذج ملائم لها، فعندئذ علّل سبب ثقتنا بقبول تنبؤات هذا النموذج.
- ٣- ما هو سبب وجود المركبة العشوائية في نموذج المتسلسلة الزمنية، وكيف تفسّر الافتراض من أنّ هذه المركبة من طبيعة الضجيج الأبيض.
- ٤- ما هي الغاية من استخدام طريقة النسبة إلى متوسط متحرك في دراسة الأثر الموسمي.
- ٥- لتكن لدينا البيانات الآتية لعينة مأخوذة من مسار متسلسلة زمنية:

t	1	2	3	4	5	6	7	8	9	10
x_t	63	101	84	116	110	137	100	94	129	98

والمطلوب ما يلي:

- أ- تعيين الاتجاه العام الخطي لهذه المتسلسلة الزمنية.
- ب- توليد متسلسلة زمنية أخرى من المتسلسلة السابقة باستخدام متوسطات متحركة بطول يساوي 3، ومن ثمّ رسم بصمة المتسلسلة الزمنية الناتجة عن المتوسطات المتحركة، قارن الشكل الناتج مع البصمة للمتسلسلة الزمنية الأصل، ماذا تلاحظ.
- ج- تعيين معادلة كثيرة الحدود المناسبة للاتجاه العام لهذه المتسلسلة الزمنية باستخدام طريقة الفروق المتتالية.
- ٦- لتكن لدينا البيانات الآتية لعينة مأخوذة من مسار متسلسلة زمنية:

t	1	2	3	4	5	6	7	8	9	10
x_t	12	22	18	14	27	16	13	26	18	29

والمطلوب ما يلي:

- أ- رسم بصمة هذه المتسلسلة الزمنية.
- ب- حساب معامل الخشونة لهذه المتسلسلة الزمنية.
- ج- توليد متسلسلة زمنية من المتسلسلة السابقة باستخدام متوسطات متحركة بطول يساوي 2.
- ٧- لتكن لدينا البيانات الآتية لعينة مأخوذة من مسار متسلسلة زمنية:

t	1	2	3	4	5	6	7	8	9	10
x_t	3	6	10	16	25	32	40	46	50	53

والمطلوب ما يلي:

- أ- رسم بصمة هذه المتسلسلة الزمنية.
- ب- استخدم الدالة المنطقية في تعيين الاتجاه العام لهذه المتسلسلة الزمنية.
- ج- تنبأ بالقيمتين الموافقتين للفجوتين الزمنيّتين 11 و 12.

٨- عيّن كثيرة الحدود المقدّرة للاتجاه العام للمتسلسلة الزمنية الآتية:

t	1	2	3	4	5	6	7	8	9	10	11	12
x_t	1	5	8	14	26	35	50	64	82	98	120	145

٩- لتكن لدينا المشاهدات المقدّمة في الجدول الآتي والمأخوذة من مسار متسلسلة زمنية تصف أرباح مضارب في البورصة (مقدّرة ب 1000 وحدة نقدية) في كل شهر وعلى مدى 28 شهراً:

t الشهر	1	2	3	4	5	6	7	8	9	10	11	12	13	14
x_t	3	1	2	4	6	7	5	3	2	5	9	11	8	4
t الشهر	15	16	17	18	19	20	21	22	23	24	25	26	27	28
x_t	3	6	11	15	12	8	4	8	13	17	15	7	5	8

والمطلوب ما يلي:

- أ- ارسم بصمة هذه المتسلسلة الزمنية، ومن ثمّ بيّن أيّا من نموذجي الجمع أو الضرب أكثر توافقاً مع هذه المتسلسلة الزمنية مع التعليل.
- ب- عيّن الاتجاه العام الخطّي لهذه المتسلسلة الزمنية.
- ج- بيّن هل كانت الأرباح الشهرية لهذا المضارب مستقلة أم لا؟
- د- عيّن الدالة المقدّرة للمركّبة الدورية لهذه المتسلسلة الزمنية.
- هـ- ولّد بعض التنبؤات من النموذج الناتج.


١٠- لتكن لدينا البيانات المقدّمة من خلال الجدول الآتي الذي يمثّل عيّنة مأخوذة من مسار متسلسلة زمنية لكمية منتجات زراعية مصدّرة من إحدى المدن إلى المدن الأخرى في نهاية كل فصل من الفصول الأربعة من العام (مقدّرة بالطن):

		الفصل			
		1	2	3	4
العام	2010	125	225	143	133
	2011	100	320	150	135
	2012	111	285	135	150
	2013	120	240	155	140
	2014	115	275	135	125
	2015	105	310	120	138


والمطلوب ما يلي:

- أ- رسم بصمة هذه المتسلسلة الزمنية.
- ب- تقدير المركّبات الموسميّة لهذه المتسلسلة الزمنية باستخدام طريقة النسبة إلى متوسط متحرك.


١١- لتكن لدينا العروض الآتية لمتسلسلة زمنية وقد تمّ توفير نماذج لها وفقاً لطريقة التجزئة (أمعن النظر في هذه الأشكال) مع الاتجاه العام والتنبؤات وفقاً لهذه النماذج:



المتسلسلة الزمنية الأصل



توفيق للمتسلسلة الأصل مع تنبؤات لدور كامل



توفيق للمتسلسلة الأصل مع تنبؤات لدور كامل

والمطلوب هو تحديد أيّ النموذجين الأخيرين هو نموذج جمع كتوفيق للمتسلسلة الأصل، وكيف تفسّر استنتاجك؟

الفصل الثالث عشر

الأرقام القياسية

INDEX NUMBERS

(١٣,١) مفهوم الرقم القياسي

Concept of Index Number

في الحقيقة يعود استخدام الأرقام القياسية إلى أكثر من قرنين من الزمن، حيث استخدمها الاقتصادي والمؤرخ الإيطالي كارلي (1720-1795) Gian Rinaldo Carli عام 1764 لمقارنة الأسعار في إيطاليا لسنة 1750 بالأسعار في سنة 1500، وكان استخدام الأرقام القياسية آنذاك حكراً على الاقتصاديين، ولكن بسبب التطبيقات الواسعة لهذا النوع من العلوم تم كسر هذا الاحتكار بحيث أصبح وسيلة في يد كل من يريد استخدام الرقم القياسي، ومن ثم شاع استخدامها، وتطور مفهومها بحيث أصبح هناك العديد من المقاييس في هذا المجال سنأتي على ذكر بعضها لاحقاً.

في الواقع أصبحت الأرقام القياسية مستخدمة في الكثير من القطاعات العلمية وعلى وجه الخصوص من قبل داسي علم الاقتصاد، والاجتماع، والسياسة، والإدارة، والزراعة، و...، وذلك من أجل إجراء مقارنات وقياس التغيرات التي تطرأ في مجالات أعمالهم. هذا من جانب، ومن جانب آخر فقد تنوعت استخدامات الأرقام القياسية، فنجد على سبيل المثال: الرقم القياسي لأسعار الجملة، والرقم القياسي للصادرات، والرقم القياسي للواردات، والأرقام القياسية للإنتاج الزراعي، والأرقام القياسية للإنتاج الصناعي، وتكاليف المعيشة. كذلك يمكننا بمعونة الأرقام القياسية مقارنة متوسط سعر عدة مواد في سنة واحدة مع متوسط سعر الكمية نفسها من ذات المواد في عدد من السنوات المختلفة الأخرى. هكذا نجد أن الرقم القياسي (للأسعار مثلاً) يفيدنا في فهم وتفسير تغير الظروف الاقتصادية والتجارية مع مرور الزمن.

ما هو الرقم القياسي؟

إن الرقم القياسي هو عبارة عن مؤشر إحصائي يقيس التغير النسبي الذي يطرأ على ظاهرة معينة (مثل: السعر، أو الكمية، أو القيمة، أو النشاط، أو الدرجات، أو) بالنسبة إلى أساس معين قد يكون فترة زمنية معينة أو مكاناً جغرافياً محدداً أو مؤسسة أو...، حيث تؤخذ قيمة الظاهرة كأساس لحساب الرقم القياسي، ويُطلق على الوقت أو المكان الذي تنسب إليه الظاهرة اسم **دورة الأساس** Base Period، وفي المراجع العربية تتنوع الترجمات لهذه العبارة، فإذا كانت الدراسة في مجال الدراسات الاقتصادية والتجارية، فإنه غالباً ما يُطلق عليها اسم **فترة الأساس** أو **عام الأساس** أو... لارتباطها بعامل الزمن، وفي حال كانت الدراسة في مجال الدراسات الطبية والنفسية، فإنه غالباً ما يُطلق عليها اسم **حالة الأساس** أو **الوضع الأساس** أو... لارتباطها بالحالة المرضية التي قيد الدراسة. أما إذا كانت الدراسة في مجال الدراسات الجغرافية أو المتعلقة بمفاهيم جغرافية، فإنه يُطلق عليها اسم **المكان الأساس** أو **الموقع الأساس**. لكننا سنعتمد في هذا الفصل تسمية **دورة الأساس** مع ذكر بعض المسميات المرافقة لها بين الحين والآخر. علماً أن دورة الأساس هنا قد تعني:

- شركة أو مؤسسة أو مدرسة أو ...
- فترة زمنية محددة ، ومن الممكن أن يكون طول هذه الفترة الزمنية ثواني (كأن تكون الظاهرة التي قيد الدراسة هي عدّ جسيمات ألفا المنطلقة من مادة مشعة - كنجربة رذر فورد جايجر مثلاً)، ومن الممكن أن تمتد إلى ساعات أو أعوام أو قرون من الزمن (كما في دراسة قضايا الحروب).
- حيز ما من الفضاء ، وهذا الحيز قد يكون خطياً كأن يكون سلك الكهرباء للتوتر العالي المعلق بين عامودين (كأن تكون الظاهرة التي قيد الدراسة هي قياس المسافة التي يصل إليها المجال الكهربائي المولد من مرور تيار كهربائي بجهد 100 كيلو فولت في هذا السلك في منطقتين مختلفتين)، ومن الممكن أن يكون لهذا الحيز بُعد ثنائي كأن تكون المساحة التي يبنى عليها منزل أو بلدة أو ...، ومن الممكن أن يكون ثلاثي البعد كأن تكون طبقة الجو المحيطة بالأرض التي يُسمح فيها بالمرور للطيران المدني. هكذا نلاحظ أن هذا الحيز يمكن أن يكون صغيراً جداً كما في الدراسات الميكروسكوبية (قد يصل إلى الميكرو والنانو متر) أو قد يكون كبيراً جداً كما في الدراسات المايكروسكوبية (قد يصل إلى آلاف وملايين الكيلومترات).
- أما الشيء الذي ستنسب بياناته إلى بيانات دورة الأساس (التي يجب أن تكون من ذات الطبيعة) فإنها تدعى **دورة المقارنة** Compare Period أو **الدورة الحالية (أو الدورة الجارية)** Current Period، وبما أن البيانات التي ستنسب بعضها إلى بعض من ذات الطبيعة فإن الحوار السابق بخصوص دورة الأساس يبقى ساري المفعول على دورة المقارنة، والجمل الآتية توضح لنا العلاقة النسبية لدورة المقارنة مع دورة الأساس:
- ١ - نرغب في معرفة مدى التغير الذي طرأ على أسعار الفاكهة بين عامي 2004 و 2014، فيكون عام 2004 **دورة الأساس** في حين يصبح عام 2014 هو **دورة المقارنة**.
- ٢ - نرغب في معرفة مدى التغير الذي طرأ على النشاط الإشعاعي لمادة مشعة (من خلال معرفة شدة وكمية الجسيمات المنطلقة من هذه المادة) بين عشر ثوان سبقت والآن، فتكون الثانية التي مرت قبل عشرة ثوان من الآن هي **دورة الأساس** في حين تصبح الثانية التي نقيس خلالها عدد الجسيمات المنطلقة من المادة المشعة هي **دورة المقارنة**.
- ٤ - نرغب في معرفة مدى التغير الذي طرأ على عدد ضحايا الحروب في القرن الرابع عشر وما يقابلها من ضحايا في القرن العشرين (القرن الماضي)، فيكون القرن الرابع عشر هو **دورة الأساس** في حين يصبح القرن العشرين هو **دورة المقارنة**.
- ٥ - نرغب في معرفة مدى التغير الحاصل لكميات بعض المنتجات لشركة منتجة لقطع سيارات هونداي في اليابان مع شركة أخرى للمنتجات نفسها في الهند، فعندئذ الشركة المنتجة لقطع سيارات هونداي في اليابان تؤخذ **كدورة أساس** في حين أن الشركة المنتجة لقطع سيارات هونداي في الهند تلعب دور **دورة المقارنة**.
- ٥ - نرغب في معرفة مدى التغير الحاصل لنشاط جراثيم (من خلال معرفة سرعة التكاثر ونفث السموم الناتجة عن الجراثيم - ...) في مزرعة جرثومية بحجم 15 ستيماً مكعباً، والجراثيم الأخرى من ذات النوع التي تعيش في الهواء الطلق، فعندئذ المزرعة ذات حجم 15 ستيماً مكعباً تؤخذ **كدورة أساس** في حين أن الفضاء الذي تعيش فيه الكائنات الحية على الأرض هو **دورة المقارنة**.
- هكذا نجد أن الرقم القياسي هو مؤشر إحصائي يوضح المقارنة النسبية بين رقمين أحدهما يُستخدم كأساس للمقارنة. بعبارة أخرى، فإن الرقم القياسي يقيس التغير النسبي لقيمتين لأشياء قيد الدراسة (صيغة الجمع هنا - لأشياء - إنما للتعميم ولا تفيد الحصر، بمعنى أنه قد تكون الدراسة معنية بشيء واحد فقط أو شيئين أو أكثر من ذلك) من:
- فترة زمنية إلى أخرى، علماً أن إحدى هاتين القيمتين تمثل الفترة الزمنية المعنية (دورة الأساس) لهذا الشيء، والقيمة الأخرى تمثل هذا الشيء في الفترة الزمنية الأخرى (دورة المقارنة).

- أو من مكان إلى آخر، وفي هذه الحالة تكون إحدى هاتين القيمتين تمثل المكان المعني (دورة الأساس) لهذا الشيء، والقيمة الأخرى تمثل هذا الشيء في المكان الآخر (دورة المقارنة).
- أو من حالة إلى أخرى، وهنا تكون إحدى هاتين القيمتين تمثل الحالة المعنية (دورة الأساس) لهذا الشيء، والقيمة الأخرى تمثل هذا الشيء لدى الحالة الأخرى (دورة المقارنة).
- أخيراً نشير إلى الآتي:

١- من الممكن أن يكون لدينا معطيات عديدة تمثل كل واحدة منها فترة زمنية (أو مكان أو حالة)، فعندئذ ليس بالضرورة أن تكون الفترة الزمنية الأقل (أو المكان الأقرب أو الحالة الأدنى) هي فترة الأساس، وكذلك ليس بالضرورة أن تؤخذ كفترة مقارنة، بل من الممكن اختيار أي من هاتين الفترتين الزمنيّتين (أو المكانين أو الحالتين) كفترة أساس أو مقارنة وذلك حسب طبيعة المسألة وشروطها ومتطلباتها، فلو افترضنا أنه لدينا المعطيات الآتية لمتوسط أسعار كيلو اللحم في بلد ما مقدراً بوحدات نقدية:

الجدول (١، ١٣)

العام year	متوسط سعر كيلو اللحم Price -year
1995	10
2000	13
2005	18
2010	25
2015	40

فيمكننا هنا أن نأخذ أيًا من هذه الأعوام على أنه دورة الأساس، فإذا كان اهتمامنا منصباً على مقارنة الأسعار إلى ما كانت عليه في عام 2000 مثلاً، فعندئذ يكون عام 2000 هو دورة الأساس، وأي عام آخر ستنسب قيمته الممثّلة إلى القيمة 13 (لعام 2000) سيلعب دور دورة المقارنة.

٢- نشير إلى أنه عند اختيار دورة الأساس ينبغي النظر بعناية فائقة إلى الأمور الآتية:

- أ- ألا تكون دورة الأساس من الماضي البعيد جداً عن دورة المقارنة.
- ب- أن تكون دورة الأساس والمقارنة من ذات الطبيعة، بمعنى أنه لا يجوز هنا أن نستخدم شهراً لدورة الأساس ويوماً لدورة المقارنة.
- ج- أن تكون وحدات القياس المستخدمة في دورتي الأساس والمقارنة من ذات الطبيعة أيضاً.
- د- في حال الأخذ بالحسبان الفترات السابقة فإنه يجب التفكير ملياً في تحديد أيّ الدورتين ستكون دورة أساس وبشكل خاص عند استخدام المؤشرات الموزونة (سنأتي على ذكرها لاحقاً).
- لقد لاحظنا أن الأرقام القياسية تشغل مكاناً بارزاً بين المقاييس الإحصائية المستخدمة لدراسة الظواهر الاجتماعية، والاقتصادية، والعلمية، لا بل يؤكد الاقتصاديون أن الأرقام القياسية تعدّ وسيلة فعّالة ومهمّة جداً من وسائل الإحصاء الحديث المستخدمة في الاقتصاد.
- بهذا الشكل يكون الطريق قد مهّد جيداً لتعريف الرقم القياسي الذي سيقدمه لنا التعريف الآتي.

(١, ١, ١٣) تعريف (الرقم القياسي Index Number)

إنَّ الرقم القياسي هو عدد في صيغة نسبية يُستخدم لقياس التغيُّر النسبي لظاهرة ما (مثل: السعر، الكمية، الحرارة، و....) أو لعدة ظواهر من فترة زمنية إلى أخرى، أو من مكان إلى آخر، أو من حالة إلى أخرى.

(١, ١, ١٣) ملاحظات

١- إنَّ الرقم القياسي يُدعى مؤشراً أيضاً، وهذا ما سنستخدمه لاحقاً في هذا الفصل.

٢- في الواقع للأرقام القياسية أوجه مختلفة في المجتمعات الإحصائية، فقد تصادفنا تعاريف أخرى قد تختلف عن ذلك الذي قدّم في التعريف السابق، فعلى سبيل المثال قد يعرف البعض الرقم القياسي على أنه معدل المتسلسلة الزمنية كما يرد في بعض الدراسات للتغيرات الموسمية في المتسلسلات الزمنية، في حين يرى البعض الآخر أنَّ الرقم القياسي هو قيمة نسبية تُظهر بشكل مباشر التغيُّر المتوسط في الظواهر الاجتماعية كما يرد في بعض دراسات علم الاجتماع. هكذا يلاحظ أنَّ دور الرقم القياسي في هذه الحالات إنما يقتصر على وصف إجمالي التغيُّر في الظاهرة ولا يتعدها إلى حالة التعميم (وهذه التعاريف للرقم القياسي تنضوي تحت الدراسات التقليدية)، ولكن الدراسات الحديثة تولي الرقم القياسي بعداً أكثر شمولية مما سبق، فهي ترى أنَّ الرقم القياسي يجب ألا يقتصر عمله على الوصف الإجمالي للتغيُّر في الظاهرة فقط، وإنما يجب أن يصف دور كلٍّ من العوامل التي أدت إلى إحداث هذا التغيُّر الإجمالي أيضاً سواء في دورة الأساس أو دورة المقارنة.

بناءً على ما سبق سيكون لدينا نماذج مختلفة من الأرقام القياسية، وسنبداها بالمؤشر الآتي.

(١٣, ٢) الأرقام القياسية البسيطة

Simple Index Numbers

في هذا الفصل سنقدّم العديد من الأرقام القياسية (المؤشرات) مبتدئين بالبسيط منها ومن ثمَّ ننتقل إلى الأعم فالأكثر عمومية. إنَّ الأرقام القياسية التي تنشأ عن شيء واحد فقط تُسمى أرقاماً قياسية بسيطة، وهذا يعني أنَّ الرقم القياسي البسيط يقيس التغيُّر النسبي بمتغيّر واحد فقط، والتعريف الآتي يوضح لنا هذا المفهوم.

(١, ٢, ١٣) تعريف (الرقم القياسي البسيط Simple Index Number)

لتكن p_o قيمة تمثل شيئاً (واحدًا فقط) في دورة الأساس، وكذلك p_c قيمة تمثل ذلك الشيء نفسه في دورة المقارنة، فعندئذٍ تُدعى النسبة المئوية الآتية (التي سنرمز لها بـ I_S) رقماً قياسياً بسيطاً:

$$I_S = \frac{p_c}{p_o} \times 100 \% \quad [13,1]$$

(١, ٢, ١٣) ملاحظات

١- من الواضح أنَّ الرقم القياسي البسيط (المؤشر البسيط) هو عدد مجرد من وحدة القياس، وذلك لأنها ناتج قسمة مقدار على مقدار آخر له وحدة القياس نفسها؛ لأنَّ البيانات المقسومة على بعضها من ذات الطبيعة (ريال على ريال، أو كغ على كغ، أو ...).

٢- إنَّ قيمة الرقم القياسي البسيط لأي شيء من دورة الأساس يساوي 100%، ومن ثمَّ قيمة الرقم القياسي البسيط المحسوب بالعلاقة السابقة [13,1] خاص بدورة المقارنة.

٣- إنَّ الرقم القياسي البسيط I_S هو قيمة نسبية Relative Value تقيس التغيُّر النسبي لقيمتين لشيء واحد قيد الدراسة من

فترة زمنية إلى أخرى، أو من مكان إلى آخر أو من حالة إلى أخرى، وكذلك يُلاحظ أن الأشياء في هذا النوع من الدراسة تُدرس كلاً على حدة. لكن إذا كان لدينا أكثر من شيء واحد خاضع للدراسة نفسها فإنه يُنصح بجمع النتائج في جدول واحد.

٤- عندما يكون الرقم القياسي البسيط I_S ناتج عن دراسة الأسعار، فعندئذ يُدعى I_S **مؤشر السعر البسيط** The Simple Price Index.

٥- إذا كانت قيمة المؤشر I_S أكبر من 100، فإننا نطرح 100 من قيمة هذا المؤشر، والنتيجة هي نسبة الزيادة في قيمة الشيء الذي هو قيد الدراسة من دورة الأساس إلى دورة المقارنة، وتقرأ كنسبة مئوية. وأما إذا كانت قيمة المؤشر I_S أقل من 100، فعندئذ نطرح قيمة هذا المؤشر من 100 والنتيجة هي النسبة المئوية لذلك النقص في تكلفة الشيء الذي قيد الدراسة في دورة الأساس مما هي عليه في دورة المقارنة، وتقرأ كنسبة مئوية أيضاً.

٦- بفرض أنه لدينا k شيء T_1, T_2, \dots, T_k وكان $I_{S,1}, I_{S,2}, \dots, I_{S,k}$ هي الأرقام القياسية البسيطة (المؤشرات البسيطة) لتلك الأشياء على الترتيب، فعندئذ يُقال عن المقدار الآتي إنه **المعدل البسيط** Simple Average للقيم النسبية لتلك الأشياء:

$$SA := \frac{1}{k} \sum_{i=1}^k I_{S,i} \quad [13,2]$$

وعندما تكون الدراسة متعلقة بالأسعار فإنه يُدعى **المعدل البسيط للقيم النسبية للأسعار** Simple Average of Price Relatives، ويقرأ الناتج كنسبة مئوية.

٧- في دراستنا المقبلة:

أ- سنرمز بـ $p_{o,1}, p_{o,2}, \dots, p_{o,k}$ للقيم الناتجة عن دراسة الأشياء T_1, T_2, \dots, T_k في دورة الأساس على الترتيب (استخدامنا للحرف (o) في دليل القيم جاء من كلمة old، للدلالة على دورة الأساس بمعنى الدورة القديمة).

ب- سنرمز بـ $w_{o,1}, w_{o,2}, \dots, w_{o,k}$ لأوزان (أو تكرارات) القيم $p_{o,1}, p_{o,2}, \dots, p_{o,k}$ على الترتيب.

ج- سنرمز بـ $p_{c,1}, p_{c,2}, \dots, p_{c,k}$ للقيم الناتجة عن دراسة الأشياء T_1, T_2, \dots, T_k في دورة المقارنة على الترتيب (استخدامنا للحرف (c) في دليل القيم جاء من كلمة Compare، للدلالة على دورة المقارنة أو بمعنى الدورة الجارية (أو الحالية) Current Period).

د- سنرمز بـ $w_{c,1}, w_{c,2}, \dots, w_{c,k}$ لأوزان (أو تكرارات) القيم $p_{c,1}, p_{c,2}, \dots, p_{c,k}$ على الترتيب.

(٢، ١، ٢، ١٣) أمثلة

١- لنفترض أن أسرة تهتم بموضوع تكلفة استهلاكها السنوي للمواد الغذائية (مقدرة بـ 100 كيلوغرام) المتمثلة بالفاكهة، والخضراوات، والدقيق ومشتقاته، واللحوم، وأن متوسط سعر الكيلوغرام الواحد لكل نوع من هذه السلع الغذائية (مقدراً بـ وحدة نقدية Monetary Units) قد بدأ بقيمة ما في العام (1) Price-year (دورة الأساس)، علماً أن العام (1) يمكن أن يشير إلى أي عام سابق. كذلك سنفترض أن متوسط سعر الكيلوغرام الواحد (مقدراً بالوحدة النقدية نفسها) لكل نوع من هذه السلع قد أصبح له سعر في عام تال آخر سنرمز له بـ العام (2) (دورة المقارنة)، علماً أن العام (2) ليس بالضرورة أن يكون العام التالي مباشرة للعام (1) وإنما هو عام آخر يأتي بعد العام (1)، وكذلك ليس بالضرورة أن يكون العام (2) هو العام الحالي (أو العام الجاري) وإنما يمكن له أن يكون عاماً سابقاً للعام الحالي ولكنه بعد العام (1) حتماً. الآن لو افترضنا أن أسعار هذه السلع في العامين (1) و(2) مقدمة كما في الجدول الآتي:

الجدول (٢، ١٣. أ)

م. ر. <i>i</i>	المنتج	دورة الأساس السعر في العام (1) Price -year	دورة المقارنة السعر في العام (2) Price -year
1	الفاكهة	$5 = p_{o,1}$	$6 = p_{c,1}$
2	الخضروات	$6 = p_{o,2}$	$4 = p_{c,2}$
3	الدقيق ومشتقاته	$2 = p_{o,3}$	$2 = p_{c,3}$
4	اللحوم	$20 = p_{o,4}$	$33 = p_{c,4}$

فعندئذ لنقم بحساب قيم المؤشرات البسيطة (الأرقام القياسية البسيطة) لأسعار هذه السلع الأربع، فنجد (بحسب العلاقة [13,1]) أن المؤشر البسيط لسعر سلعة:

أ- الفاكهة يساوي:

$$I_{S,1} = \frac{p_{c,1}}{p_{o,1}} \times 100 = \frac{6}{5} \times 100 = 120\%$$

ومن ثم نسبة الزيادة في أسعار الفاكهة من دورة الأساس إلى دورة المقارنة يساوي 20%.

ب- الخضراوات تساوي $I_{S,2} = \frac{4}{6} \times 100 = 67\%$ ، ومن ثم نسبة النقصان في أسعار الخضراوات من دورة الأساس إلى دورة المقارنة يساوي 33%.

ج- الدقيق ومشتقاته تساوي $I_{S,3} = 100\%$ ، ومن ثم لا وجود لأي تغير في أسعار الدقيق ومشتقاته من دورة الأساس إلى دورة المقارنة.

د- اللحوم تساوي $I_{S,4} = 165\%$ ، ومن ثم نسبة الزيادة في أسعار اللحوم من دورة الأساس إلى دورة المقارنة تساوي 65%.

هكذا يمكننا تدوين نتائج هذه الدراسة في الجدول الآتي:

الجدول (٢، ١٣. ب)

م. ر. <i>i</i>	المنتج	دورة الأساس السعر في العام (1)	مؤشر السعر في العام (1) Index-year 1	دورة المقارنة السعر في العام (2)	مؤشر السعر في العام (2) Index-year 2
1	الفاكهة	5	100 %	6	120 %
2	الخضراوات	6	100 %	4	67 %
3	الدقيق ومشتقاته	2	100 %	2	100 %
4	اللحوم	20	100 %	33	165 %

ومنه نجد (بحسب العلاقة [13,2]) أن قيمة معدل المؤشر البسيط لأسعار السلع التي قيد الدراسة تساوي:

$$SA := \frac{\sum_{i=1}^4 I_{S,i}}{4} = \frac{120 + 67 + 100 + 165}{4} = \frac{452}{4} = 113$$

ومن ثمَّ المعدَّل البسيط للسعر 113%، وهذا يعني أنَّ المعدَّل البسيط للقيم النسبية للسعر يساوي 113%، وبالتالي يوجد ارتفاع عام في أسعار هذه السلع بمعدَّل 13% من العام (1) إلى العام (2).

٢- نعلم أنَّه في كل مرحلة ثانوية ثلاث مستويات دراسية (أول، وثان وثالث ثانوي). الآن سنفترض أننا نرغب في معرفة التغيُّر الطارئ على تحصيل طلبة هذه المراحل بين مدارس المدن والأرياف، فقمنَّا باختيار عشوائي لإحدى المدن، ومن ثمَّ اختيار عشوائي لريف من أريافها، وبعد ذلك أحصيت النسب المئوية لأعداد الطلاب الذين حصلوا على معدَّل عام أكثر من 92% في نهاية العام الدراسي في كل مستوى من المستويات الثلاث، فكانت لدينا النتائج الآتية:

الجدول (٣، ١٣. أ)

دورة المقارنة في الريف المكان (2)	دورة الأساس في المدينة المكان (1)	طلاب	ر.م. <i>i</i>
75%	65%	الأول الثانوي	1
60%	52%	الثاني الثانوي	2
78%	83%	الثالث الثانوي	3

لاحظ أننا جعلنا في هذا الجدول المدينة هي دورة الأساس (مكان الأساس، ومن الممكن تسميتها المكان (1) أيضاً)، والريف التابع لهذه المدينة هو دورة المقارنة (مكان المقارنة، ومن الممكن تسميتها المكان (2) أيضاً). بالطبع كان من الممكن أن نأخذ العكس أيضاً حيث تُفسَّر النتائج بشكل معكوس في هذه الحالة. الآن لحساب المؤشر البسيط لنسب الطلاب الذين حصلوا على معدَّل عام أعلى من 92% نجد (بحسب العلاقة [13,1]) أنَّ طلاب مستوى:

أ- الأول ثانوي يساوي:

$$I_{S,1} = \frac{P_{c,1}}{P_{o,1}} \times 100 = \frac{0.75}{0.65} \times 100 = 115.38\%$$

وهذا يعني أنَّ نسبة طلاب الأول ثانوي الذين حصلوا على معدَّل عام في نهاية العام الدراسي أكثر من 92% من أبناء الريف تزيد على نسبة طلاب الأول ثانوي الذين حصلوا على المعدَّل نفسه من أبناء المدينة بنسبة تساوي 15.38%.

ب- الثاني ثانوي يساوي $I_{S,2} = \frac{0.60}{0.52} \times 100 = 115.38\%$ ، وهذا يعني أنَّ نسبة طلاب الثاني ثانوي الذين حصلوا على معدَّل عام في نهاية العام الدراسي أكثر من 92% من أبناء الريف تزيد على نسبة طلاب الثاني ثانوي الذين حصلوا على المعدَّل نفسه من أبناء المدينة بنسبة تساوي 15.38% أيضاً.

ج- الثالث ثانوي يساوي $I_{S,3} = 93.98\%$ ، وهذا يعني أنَّ نسبة طلاب الثالث ثانوي الذين حصلوا على معدَّل عام في نهاية العام الدراسي أكثر من 92% من أبناء الريف تقل عن نسبة طلاب الثالث ثانوي الذين حصلوا على المعدَّل نفسه من أبناء المدينة بنسبة تساوي 6.02%.

وبوضع قيمة المؤشر البسيط 100% لنسب الطلاب في المدينة، والذين حصلوا على معدَّل عام في نهاية العام الدراسي أكثر من 92% في كل مستوى من المستويات الثلاث، فعندئذ يمكننا تدوين نتائج هذه الدراسة في الجدول الآتي:

الجدول (٣، ١٣. ب)

م. ر. <i>i</i>	طلاب	في المدينة المكان (1)	مؤشر معدّل الطلاب في المدينة المكان (1)	في الريف المكان (2)	مؤشر معدّل الطلاب في الريف المكان (2)
1	الأول الثانوي	0.65	100 %	0.75	115.38 %
2	الثاني الثانوي	0.52	100 %	0.60	115.38 %
3	الثالث الثانوي	0.83	100 %	0.78	93.98 %

ومنه نجد (بحسب العلاقة [13,2]) أن قيمة المعدل البسيط للقيم النسبية للنسب التي هي قيد الدراسة تساوي:

$$SA := \frac{115.38 + 115.38 + 93.98}{3} = \frac{324.74}{3} = 108.25\%$$

ومن ثم المعدل البسيط للقيم النسبية للنسب التي قيد الدراسة يساوي 108.25%، وهذا يعني أن الذين حصلوا على معدل عام في نهاية العام الدراسي أكثر من 92% من أبناء الريف يزيد على الذين حصلوا على المعدل نفسه من العام نفسه من أبناء المدينة بمقدار 8.25%.

٣- تقوم شركة تجارية بحملة إعلامية لترويج منتجاتها، ولذلك تدفع لوسائل الإعلام المختلفة مبلغاً من المال في بداية العام الذي تقرر فيه بدء حملتها الإعلامية (القيم الآتية مقدرة بـ 1000 وحدة نقدية)، فإذا كانت المبالغ المدفوعة في عام 2010 و 2014 لمؤسسة واحدة فقط من مؤسسات: الصحافة، والرأي، وإعلانات الطرق، والمذياع مقدمة كما في الجدول الآتي:

الجدول (٤، ١٣. أ)

م. ر. <i>i</i>	المؤسسة الإعلامية Media Foundation	مدفوعات المؤسسة في 2010 Price – year 2010	مدفوعات المؤسسة في 2014 Price – year 2014
1	الصحافة Press	25	32
2	الرأي Television	65	78
3	إعلانات الطرق Roads ads	10	15
4	المذياع Radio	15	12

فعندئذ (بحسب العلاقة [13,1]) نجد أن قيمة المؤشر البسيط في تكلفة:

أ- النشر في الصحافة يساوي:

$$I_{S,1} = \frac{P_{c,1}}{P_{o,1}} \times 100 = \frac{32}{25} \times 100 = 128\%$$

ومن ثم نسبة الزيادة في تكلفة النشر في الصحافة من دورة الأساس (عام 2010) إلى دورة المقارنة (عام 2014) تساوي 28%.

ب- الإعلان في الرأي (التلفزيون) يساوي $I_{S,2} = \frac{78}{65} \times 100 = 120\%$ ، ومن ثم نسبة الزيادة في تكلفة الإعلان في الرأي من دورة الأساس إلى دورة المقارنة تساوي 20%.

ج- الإعلانات الطرقية تساوي $I_{S,3} = 150\%$ ، ومن ثم نسبة الزيادة في تكلفة الإعلانات الطرقية من دورة الأساس إلى دورة المقارنة تساوي 50%.

د- الإعلانات في المذيع (الراديو) تساوي $I_{S,4} = 80\%$ ، ومن ثمَّ نسبة النقصان في تكلفة الإعلانات الإذاعية من دورة الأساس إلى دورة المقارنة تساوي 20%.

الآن بوضع قيمة المؤشر البسيط 100% لمدفوعات المؤسسة في العام 2010، فإنه يمكننا تدوين نتائج هذه الدراسة في الجدول الآتي (٣، ١٣. ب)، حيث نجد منه (بحسب العلاقة [13,2]) أنَّ قيمة المعدل البسيط للقيم النسبية لتكاليف الإعلام تساوي:

$$SA := \frac{128+120+150+80}{4} = \frac{478}{4} = 119.5\%$$

ومن ثمَّ المعدل البسيط للسعر 119.5%، ومنه نلاحظ وجود ارتفاع عام في تكاليف الإعلانات في المؤسسات الأربع بمعدل 19.5% من العام 2010 إلى العام 2014.

الجدول (٤، ١٣. ب)

مؤشر التكلفة للعام 2014	مدفوعات المؤسسة في العام 2014	مؤشر التكلفة للعام 2010	مدفوعات المؤسسة في العام 2010	المؤسسة الإعلامية	ر.م. i
128%	32	100%	25	الصحافة	1
120%	78	100%	65	الرائي	2
150%	15	100%	10	إعلانات الطرق	3
80%	12	100%	15	المذيع	4

إنَّ تفسير الزيادة أو النقص في مثل هذه المسائل ليس بالأمر البسيط غالباً، فعلى سبيل المثال إذا أخذنا موضوع الزيادة، فإنَّ ذلك قد يكون متعلّقاً بجملة أسباب متداخلة منها على سبيل المثال لا الحصر: الغلاء الذي طرأ على أسعار المواد التي تستخدمها وسائل الإعلام خلال الفترة الزمنية 2010 إلى 2014، والغلاء العام للمعيشة الذي حصل ما بين عامي 2010 و 2014 والذي أجبر هذه المؤسسات على زيادة أجور عاملاتها ومن ثمَّ الزيادة في التكلفة العامة للعمل، وقد يكون هناك أسباب أخرى كالضرائب الحكومية، و...، بمعنى آخر إنَّ إظهار المؤشر للزيادة لا يعني بالضرورة أنَّ هذه المؤسسات رابحة، فقد تكون خاسرة في الواقع. أما ظهور النقصان في قيمة المؤشر فقد يعطي دلالات على الخسارة أو ضعف الإقبال على منتج هذه المؤسسات، فعلى سبيل المثال قد يُفسَّر النقصان لمؤشر المذيع على إحجام أكثرية الناس عن الاستماع إلى المذيع ومن ثمَّ قلة العروض التي تقدّم إليها.

إذاً حتى الآن قمنا بتقديم المؤشر البسيط، ولكن قد يصادفنا في الكثير من الدراسات أرقاماً قياسية تنشأ من تغيّرات القيم لسلع مختلفة. إنَّ المؤشر الموافق لمثل هذه الحالة يُدعى **رقماً قياسياً مركباً** Composite Index Number، ومن هذه المؤشرات نقدّم المؤشر الآتي.

(٢، ٢، ١٣) تعريف (الرقم القياسي الكلي البسيط Simple Aggregate Index Number)

بفرض أنَّه لدينا k شيء T_1, T_2, \dots, T_k وكانت $P_{o,1}, P_{o,2}, \dots, P_{o,k}$ القيم الممثّلة لهذه الأشياء في دورة الأساس على الترتيب، وكذلك $P_{c,1}, P_{c,2}, \dots, P_{c,k}$ القيم الممثّلة لهذه الأشياء في دورة المقارنة على الترتيب أيضاً. عندئذ الرقم القياسي الكلي البسيط (سنرمز له بـ I_C ، ويُقرأ كنسبة مئوية) يُحسب بالعلاقة الآتية.

$$I_C = \frac{\sum_{i=1}^k P_{c,i}}{\sum_{i=1}^k P_{o,i}} \times 100\% \quad [13,3]$$

(١, ٢, ٢, ١٣) ملاحظة

إنَّ الرقم القياسي الكلي البسيط يُوجد التغيُّر المثنوي في تكلفة (أو سعر أو...) عدّة مواد من دورة إلى أخرى (أو من مكان إلى آخر)، فإذا كانت قيمة I_C أكبر من 100، فإننا نطرح 100 من قيمة هذا المؤشر، والنتيجة هي نسبة الزيادة في تكلفة (أو أسعار أو...) الأشياء من دورة الأساس إلى دورة المقارنة وتقرأ كنسبة مئوية. أما إذا كانت قيمة I_C أقل من 100، فعندئذ نطرح قيمة المؤشر من 100 والنتيجة هي النسبة المئوية لذلك النقص في تكلفة (أو أسعار أو...) الأشياء في دورة الأساس مما هي عليه في دورة المقارنة، وتقرأ كنسبة مئوية أيضاً.

(٢, ٢, ٢, ١٣) أمثلة

١- بالعودة إلى المثال / ١ / من الأمثلة (٢, ١, ٢, ١٣) (تكلفة المواد الغذائية المستهلكة من قبل أسرة)، فنجد أن:

$$\sum_{i=1}^4 p_{o,i} = 5 + 6 + 2 + 20 = 33 \quad \& \quad \sum_{i=1}^4 p_{c,i} = 6 + 4 + 2 + 33 = 45$$

ومن ثمَّ (بحسب العلاقة [13,3]) يكون للرقم القياسي الكلي البسيط I_C لتكاليف المواد الغذائية المستهلكة القيمة الآتية:

$$I_C = \frac{\sum_{i=1}^4 p_{c,i}}{\sum_{i=1}^4 p_{o,i}} \times 100 = \frac{45}{33} \times 100 = 136.36\%$$

وبما أنَّ قيمة الرقم القياسي الكلي البسيط I_C أكبر من 100 فإنَّ ذلك يُشير إلى زيادة عامّة في تكلفة المواد الغذائية التي قيد الدراسة من العام (1) إلى العام (2) بمقدار 36.36%.

٢- بالعودة إلى المثال / ٢ / من الأمثلة (٢, ١, ٢, ١٣) (طلاب الثانوي الذين حصلوا على معدّل عام أعلى من 92%)، فنجد أن:

$$\sum_{i=1}^3 p_{o,i} = 0.65 + 0.52 + 0.83 = 2 \quad \& \quad \sum_{i=1}^3 p_{c,i} = 0.75 + 0.60 + 0.78 = 2.13$$

ومن ثمَّ (بحسب العلاقة [13,3]) يكون لـ I_C الخاص بالطلاب الذين حصلوا على معدّل عام أعلى من 92% القيمة الآتية:

$$I_C = \frac{2.13}{2} \times 100 = 106.5\%$$

وبما أنَّ قيمة I_C أكبر من 100 فإنَّ ذلك يُشير إلى ارتفاع في نسبة طلاب الريف الذين حصلوا على معدّل عام أعلى من 92% من أقرانهم من طلاب المدينة التي هي قيد الدراسة بمقدار 6.5%.

٣- بالعودة إلى المثال / ٣ / من الأمثلة (٢, ١, ٢, ١٣) (تقوم شركة تجارية بحملة إعلامية سنوية لترويج منتجاتها)، فنجد أن:

$$\sum_{i=1}^4 p_{o,i} = 25 + 65 + 10 + 15 = 115 \quad \& \quad \sum_{i=1}^4 p_{c,i} = 32 + 78 + 15 + 12 = 137$$

ومن ثمَّ (بحسب العلاقة [13,3]) يكون للرقم القياسي الكلي البسيط الخاص بتكاليف الإعلانات القيمة $I_C = 119.13\%$ ، وبما أنَّ قيمة I_C أكبر من 100 فإنَّ ذلك يُشير إلى زيادة عامّة في تكلفة الإعلانات من عام 2010 إلى عام 2014 بمقدار 19.13%.

(٣, ٢, ٢, ١٣) ملاحظة

على الرغم من أن الرقم القياسي الكلي البسيط I_C سهل الحساب إلا أنَّه يُعاب عليه ما يلي:

- ١- إذا كان لأحد الأشياء **وزناً** (الذي يمثل بتكرار القيمة) كبيراً نسبياً، فعندئذ يمكن لهذا التكرار أن يسيطر على الرقم I_C ويجذبه إليه شأنه في ذلك كشأن القيم المتطرفة على المتوسط (الوسط الحسابي)، علماً أن كلمة **الوزن** هنا لها المدلول نفسه المستخدم في الفصول السابقة، فقد يعني الثقل لمادة ما، أو مضاعفات السعر لسلمة ما، أو التكرار لقيمة ما، أو...
- ٢- إذا كانت الأشياء **مدونة** من أجل كميات مختلفة فإن الرقم القياسي الكلي البسيط I_C سيؤدي إلى أجوبة مختلفة، وهذا العيب يعدّ من أسوأ العيوب للرقم I_C ؛ لأن ذلك يجعل التلاعب في قيمة هذا المؤشر ممكناً.
- ٣- إن الرقم I_C لا يأخذ في الحسبان كمية كل الأشياء المتداولة (أو السلع المباعة).

(١٣,٣) الأرقام القياسية الموزونة

Weighted Index Numbers

لقد لاحظنا أن الرقم القياسي الكلي البسيط I_C لا يأخذ بالحسبان تغير كميات (أو أسعار أو تكلفة أو...) بعض الأشياء في أي من الدورتين الأساسية والمقارنة، ومن ثم لا يمكن استخدامه إذا كان موضوع تغير كميات (أو أسعار أو تكلفة أو...) بعض الأشياء مهماً بالنسبة إلى الدراسة المطلوبة. لذلك سنقدم فيما يلي رقمين قياسييين من عائلة الأرقام القياسية الموزونة (أو المؤشر الموزون). إن هذين الرقمين القياسييين الموزونين يختلف بعضهما عن بعض في استخدام الأوزان، فالرقم الأول منهما (ويدعى مؤشر لسبيريس **Laspeyres Index**) يستخدم أوزان دورة الأساس في حين أن الرقم الآخر (ويدعى مؤشر باش **Paasche Index**) يستخدم أوزان دورة المقارنة. إن كلا منهما يقدم حلاً جزئياً للمشكلة السابقة ولكن من منطلق مختلف.

بالطبع إن تعاملنا مع تغير قيم الأوزان (التكرارات أو الكميات أو...) $w_{o,1}, w_{o,2}, \dots, w_{o,k}$ في دورة الأساس أو $w_{c,1}, w_{c,2}, \dots, w_{c,k}$ في دورة المقارنة سيمنحنا مزيداً من المعلومات (بمعنى يصبح لدينا معلومات إضافية) حول هذه الأشياء، ومن ثم سنحصل على نتائج أكثر مصداقية من الرقم I_C بخصوص الظاهرة التي هي قيد الدراسة.

فيما يلي نقدم مؤشراً يعود إلى الاقتصادي والإحصائي الألماني لسبيريس (Ernst Louis Étienne Laspeyres (1834-1913).

(١٣,٣,١) تعريف (مؤشر لسبيريس **Laspeyres index**)

بفرض أنه لدينا k شيء T_1, T_2, \dots, T_k ، وكانت $p_{o,1}, p_{o,2}, \dots, p_{o,k}$ وكذلك $w_{o,1}, w_{o,2}, \dots, w_{o,k}$ هي القيم الممثلة لتلك الأشياء وأوزانها على الترتيب في دورة الأساس، وبالمثل $p_{c,1}, p_{c,2}, \dots, p_{c,k}$ هي القيم الممثلة لتلك الأشياء في دورة المقارنة على الترتيب. عندئذ تدعى القيمة الآتية (والتي سنرمز لها بـ I_L) **مؤشر لسبيريس** لتلك الأشياء:

$$I_L = \frac{\sum_{i=1}^k p_{c,i} \cdot w_{o,i}}{\sum_{i=1}^k p_{o,i} \cdot w_{o,i}} \times 100 \% \quad [13,4]$$

نلاحظ هنا أن مؤشر لسبيريس (وهو رقم قياسي موزون) يقيس التغير النسبي بناءً على تكرارات القيم في دورة الأساس فقط، وللتوضيح فلو كانت التكرارات هي كميات السلع مثلاً، فعندئذ مؤشر لسبيريس يقيس التغير النسبي في تكلفة شراء هذه السلع من الكميات المحددة في دورة الأساس فقط.

(١٣,٣,١,١) أمثلة

١- بالعودة إلى المثال ١/ من الأمثلة (١٣,٢,١,٢) حيث البيانات مقدّمة بالجدول (١٣,٢,أ)، وسنفترض أن الكميات

المستهلكة من كل سلعة (مقدرة بالكيلوغرام) في دورة الأساس كما في الجدول الآتي:

الجدول (٥، ١٣. أ)

الكميات المستهلكة في العام (1)	المنتج	ر.م. <i>i</i>
Weights <i>w</i> _{<i>o</i>,<i>i</i>}		
400	الفاكهة	1
500	الخضراوات	2
200	الدقيق ومشتقاته	3
300	اللحوم	4

ولنحسب مؤشر لسيريس للمعطيات المقدمة آنفاً.

من أجل ذلك لنقم ببناء الجدول الآتي علماً أنّ الكميات في العام (1) مقدرة بال 100 كيلوغرام:

الجدول (٥، ١٣. ب)

الكميات في العام (1)	المنتج	ر.م. <i>i</i>	السعر في العام (2)	السعر في العام (1)	<i>P</i> _{<i>o</i>,<i>i</i>} · <i>w</i> _{<i>o</i>,<i>i</i>}	<i>P</i> _{<i>c</i>,<i>i</i>} · <i>w</i> _{<i>o</i>,<i>i</i>}
Price – year (1)			Price – year (2)			
<i>w</i> _{<i>o</i>,<i>i</i>}			<i>P</i> _{<i>c</i>,<i>i</i>}			
4	الفاكهة	1	6	5	20	24
5	الخضراوات	2	4	6	30	20
2	الدقيق	3	2	2	4	4
3	اللحوم	4	33	20	60	99
-----	Total		-----	-----	114	147

ومن ثمّ باستخدام العلاقة [13,4] يكون لمؤشر لسيريس القيمة $I_L = \frac{147}{114} \times 100 = 128.95\%$ ، ومن ثمّ نجد وفقاً لمؤشر لسيريس أنّ الإنفاق قد ازداد بمقدار 28.95%.

٢- بالعودة إلى المثال / ٢ / من الأمثلة (٢، ١، ٢، ١٣) (طلاب الثانوي الذين حصلوا على معدل عام أعلى من 92%)، وسنفترض أنّه تمّ اختيار عدد من المدن لكل مستوى من مستويات المرحلة الثانوية كما في الجدول الآتي:

الجدول (٦، ١٣. أ)

عدد المدن	المستوى	ر.م. <i>i</i>
Weights <i>w</i> _{<i>o</i>,<i>i</i>}		
3	الأول الثانوي	1
2	الثاني الثانوي	2
5	الثالث الثانوي	3

فعندئذ لحساب مؤشر لسيريس لتلك المعطيات سنقوم ببناء الجدول الآتي:

الجدول (٦، ١٣. ب)

م.ر <i>i</i>	المستوى	عدد المدن	النسب في المدن	النسب في الأرياف	$p_{o,i} \cdot w_{o,i}$	$p_{c,i} \cdot w_{o,i}$
		$w_{o,i}$	$P_{o,i}$	$P_{c,i}$		
1	الأول الثانوي	3	0.65	0.75	1.95	2.25
2	الثاني الثانوي	2	0.52	0.60	1.04	1.2
3	الثالث الثانوي	5	0.83	0.78	4.15	3.9
Total	-----	-----	-----	-----	7.14	7.35

ومن ثم باستخدام العلاقة [13,4] يكون المؤشر لسبيريس القيمة $I_L = \frac{7.35}{7.14} \times 100 = 102.94\%$ ، ومن ثم نجد وفقاً للمؤشر لسبيريس أنه ما زال هناك ارتفاع بمقدار 2.94% في نسبة طلاب الثانوي الذين حصلوا على معدل عام أعلى من 92% لدى أبناء الريف على أقرانهم من أبناء المدن.

٣- بالعودة إلى المثال / ٢ / من الأمثلة (٢، ١، ٢، ١٣) (تقوم شركة تجارية بحملة إعلامية سنوية لترويج منتجاتها)، وسنفترض أنه تم التعاقد مع عدد من المؤسسات الإعلامية في عام 2010 وفقاً للجدول الآتي:

الجدول (٧، ١٣. أ)

م.ر <i>i</i>	المؤسسة الإعلامية في عام 2014	عدد مؤسسات Weights $w_{o,i}$
1	الصحافة	3
2	الرائي	4
3	إعلانات الطرق	2
4	المذياع	2

فعندئذ لحساب مؤشر لسبيريس لتلك المعطيات نقوم ببناء الجدول الآتي:

الجدول (٧، ١٣. ب)

م.ر <i>i</i>	المؤسسة الإعلامية	عدد المؤسسات	مدفوعات المؤسسة في العام 2010	مدفوعات المؤسسة في العام 2014	$p_{o,i} \cdot w_{o,i}$	$p_{c,i} \cdot w_{o,i}$
		$w_{o,i}$	$P_{o,i}$	$P_{c,i}$		
1	الصحافة	3	25	32	75	96
2	الرائي	4	65	78	260	312
3	إعلانات الطرق	2	10	15	20	30
4	المذياع	2	15	12	30	24
Total	-----	-----	-----	-----	385	462

وباستخدام العلاقة [13,4] يكون لمؤشر لسبيريس القيمة $I_L = \frac{462}{385} \times 100 = 120$ ، ومن ثم نجد وفقاً لمؤشر لسبيريس أن الزيادة في التكاليف قد بلغت 20%.

لقد لاحظنا أن مؤشر لسبيريس يهتم بكمية المواد في دورة الأساس فقط، فإذا كانت الدراسة تتعلق بالكميات في دورة المقارنة فإن ذلك المؤشر لا يفيدنا بشيء، ولذلك سنقدم فيما يلي مؤشراً يأخذ في الحسبان كميات المواد في دورة المقارنة، ولكنه لا يهتم بكميات دورة الأساس. إن هذا المؤشر يقدمه لنا التعريف الآتي الذي يعود إلى الاقتصادي والإحصائي الألماني **باشي** Hermann Paasche (1851-1925).

(١٣, ٣, ٢) تعريف (مؤشر باشي Paasche index)

بفرض أنه لدينا k شيء T_1, T_2, \dots, T_k ، وكانت $p_{o,1}, p_{o,2}, \dots, p_{o,k}$ القيم الممثلة لهذه الأشياء في دورة الأساس على الترتيب، وكذلك سنفترض أن $p_{c,1}, p_{c,2}, \dots, p_{c,k}$ و $w_{c,1}, w_{c,2}, \dots, w_{c,k}$ القيم الممثلة لهذه الأشياء وأوزانها على الترتيب في دورة المقارنة. عندئذ نحسب قيمة الرقم القياسي الموزون لـ باشي (الذي سنرمز له بـ I_P) باستخدام العلاقة الآتية:

$$I_P = \frac{\sum_{i=1}^k p_{c,i} \cdot w_{c,i}}{\sum_{i=1}^k p_{o,i} \cdot w_{c,i}} \times 100 \% \quad [13,5]$$

نلاحظ هنا أن مؤشر باشي (وهو رقم قياسي موزون أيضاً) يقيس التغير النسبي بناءً على تكرارات القيم في دورة المقارنة فقط، وللتوضيح فلو كانت التكرارات هي كميات السلع مثلاً فعندئذ مؤشر باشي يقيس التغير النسبي في تكلفة شراء هذه السلع من الكميات المحددة في دورة المقارنة فقط.

(١٣, ٣, ٢, ١) أمثلة

١- بالعودة إلى المثال ١ / من الأمثلة (١٣, ٢, ١, ٢) (المواد الغذائية المستهلكة من قبل أسرة)، وسنفترض أن الكميات المستهلكة (مقدرة بـ 100 كيلو غرام) من السلع المذكورة في العام الآخر (العام (2) أو دورة المقارنة) مقدمة كما في الجدول الآتي علماً أن الكميات في العام (2) مقدرة بال 100 كيلو غرام:

الجدول (١٣, ٨). أ

الكميات المستهلكة في العام (2) Weights $w_{c,i}$	المنتج	ر.م. i
6	الفاكهة	1
8	الخضراوات	2
3	الدقيق ومشتقاته	3
5	اللحوم	4

فعندئذ لحساب مؤشر باشي I_P سنقوم ببناء الجدول الآتي:

الجدول (٨، ١٣. ب)

م.ر <i>i</i>	المنتج	الكميات في العام (2)	السعر في العام (1) Price – year (1)	السعر في العام (2) Price – year (2)	$P_{o,i} \cdot w_{c,i}$	$P_{c,i} \cdot w_{c,i}$
		$w_{c,i}$	$P_{o,i}$	$P_{c,i}$		
1	الفاكهة	6	5	6	30	36
2	الخضراوات	8	6	4	48	32
3	الدقيق ومشتقاته	3	2	2	6	6
4	اللحوم	5	20	33	100	165
Total	-----	-----	-----	-----	184	239

ومنه باستخدام العلاقة [13,5] يكون لمؤشر باشي القيمة $I_p = \frac{239}{184} \times 100 = 129.89$ ، فلاحظ هنا أنّ قيمة مؤشر لسيريس تأخذ قيمة أقل من مؤشر باشي، وهذا يدلّ على أنّ استخدام مؤشر لسيريس يتزايد بشكل أسرع في قطاعات السعر الأعلى.

٢- بالعودة إلى المثال /٢/ من الأمثلة (٢، ١، ٢، ١٣) (طلاب الثانوي الذين حصلوا على معدل عام أعلى من 92%)، وسنفترض مع ثبات النسب السابقة لطلاب المرحلة الثانوي الذين حصلوا على معدل عام أعلى من 92% أنّه قد تمّ اختيار عشوائي لبعض الأرياف من كل مدينة موزعة على النحو المقدم في الجدول الآتي:

الجدول (٩، ١٣. أ)

م.ر <i>i</i>	المستوى	عدد الأرياف من المدينة Weights $w_{c,i}$
1	الأول الثانوي	4
2	الثاني الثانوي	3
3	الثالث الثانوي	5

فعندئذ لحساب مؤشر باشي لهذه المعطيات سنبنّي الجدول الآتي:

جدول (٩، ١٣. ب).

م.ر <i>i</i>	المستوى	عدد الأرياف من المدينة	النسب في المدن	النسب في الأرياف	$P_{o,i} \cdot w_{c,i}$	$P_{c,i} \cdot w_{c,i}$
		$w_{c,i}$	$P_{o,i}$	$P_{c,i}$		
1	الأول الثانوي	4	0.65	0.75	2.6	3
2	الثاني الثانوي	3	0.52	0.60	1.56	1.8
3	الثالث الثانوي	5	0.83	0.78	4.15	3.9
Total	-----	-----	-----	-----	8.31	8.7

ومن ثم باستخدام العلاقة [13,5] يكون لمؤشر باشي القيمة $I_p = \frac{8.7}{8.31} \times 100 = 104.69\%$ ، ومن ثم نجد وفقاً لمؤشر باشي أنه ما زال هناك ارتفاع بمقدار 4.69% في نسبة طلاب الثانوي الذين حصلوا على معدل عام أعلى من 92% لدى أبناء الريف على أقرانهم من أبناء المدن.

٣- بالعودة إلى المثال /٣/ من الأمثلة (٢، ١، ٢، ١٣) (تقوم شركة تجارية بحملة إعلامية سنوية لترويج منتجاتها)، وسنفترض أنه تم التعاقد مع عدد من المؤسسات الإعلامية في عام 2014 وفقاً للجدول الآتي:

الجدول (١٠، ١٣. أ)

عدد مؤسسات Weights $w_{c,i}$	المؤسسة الإعلامية في عام 2014	م.ر. i
4	الصحافة	1
12	الرائي	2
3	إعلانات الطرق	3
2	المذياع	4

فعندئذ لحساب مؤشر باشي لتلك المعطيات نقوم بإنشاء الجدول الآتي:

الجدول (١٠، ١٣. ب)

م.ر. i	المؤسسة الإعلامية	عدد المؤسسات $w_{c,i}$	مدفوعات المؤسسة في عام 2010 $P_{o,i}$	مدفوعات المؤسسة في عام 2014 $P_{c,i}$	$P_{o,i} \cdot w_{c,i}$	$P_{c,i} \cdot w_{c,i}$
1	الصحافة	4	25	32	100	128
2	الرائي	12	65	78	780	936
3	إعلانات الطرق	3	10	15	30	45
4	المذياع	2	15	12	30	24
Total	-----	-----	-----	-----	940	1133

ومنه باستخدام العلاقة [13,5] يكون لمؤشر باشي القيمة $I_p = \frac{1133}{940} \times 100 = 120.5\%$ ، ومن ثم نجد وفقاً لمؤشر باشي أن الزيادة في التكاليف قد بلغت 20.5%.

(٢، ٢، ٣، ١٣) مقارنة بين مؤشري لسبيريس و باشي

١- من وجهة نظر الاقتصاد يلاحظ أن مؤشر لسبيريس يقيس نسبة الإنفاق على كميات في دورة الأساس وفقاً لتكلفة دورة المقارنة إلى الإنفاق على تلك الكميات وفقاً لتكلفة دورة الأساس، بينما مؤشر باشي يقيس نسبة الإنفاق على كميات في دورة المقارنة وفقاً لتكلفة دورة المقارنة إلى الإنفاق على تلك الكميات وفقاً لتكلفة دورة الأساس.

٢- بما أن مؤشر لسبيريس يستخدم أوزان دورة الأساس، فإنه من وجهة نظر الاقتصاد يلاحظ أن مؤشر لسبيريس قد يبالغ في تقدير الارتفاع في تكاليف المعيشة (لأن الناس قد خفضت استهلاكها من العناصر التي أصبحت أغلى نسبياً من غيرها)، في حين أن مؤشر باشي يستخدم أوزان دورة المقارنة، ولذلك فقد يظهر أنه يقلل من الارتفاع في تكاليف المعيشة.

٣- قيمة مؤشر لسبيريس تكون عادة أكبر من قيمة مؤشر باشي، أي إن $I_L \geq I_P$.

٤- يتطلب مؤشر باشي مجموعة جديدة من الأوزان التي يجب الحصول عليها في كل عام، وهذه المعلومات قد يكون الحصول عليها مكلفاً أو شاقاً، ولذلك يصعب استخدام مؤشر باشي لإجراء مقارنات من سنة إلى أخرى.

٥- بالرغم من أنه لكل من مؤشري لسبيريس وباشي مهمة محدّدة، ولا يغني أحدهما عن الآخر في كثير من الحالات. إلا أنه بسبب الفقرتين الأخيرتين / ٥ و ٦ / يرجح استخدام مؤشر لسبيريس على مؤشر باشي في كثير من الحالات.

إذاً، وكما لاحظنا أن كلا من مؤشري لسبيريس وباشي يقوم بمهمة محدّدة وبحيث لا يغني أحدهما عن الآخر، فإذا كانت الدراسة مركّزة على ما يتم استهلاكه في دورة الأساس ودورة المقارنة أيضاً، فعندئذ كل من المؤشرين السابقين يصبح قليل الفائدة، ولهذا سنقدم فيما يلي مؤشراً يأخذ في الحسبان كميات المواد في دورة الأساس ودورة المقارنة معاً. إن هذا المؤشر يُعرف باسم **المؤشر المثالي لـ فيشر** ويقدمه لنا التعريف الآتي.

(١٣, ٣, ٣) تعريف (المؤشر المثالي لـ فيشر Fisher's ideal index)

بفرض أنه لدينا k شيء T_1, T_2, \dots, T_k ، وكانت $P_{o,1}, P_{o,2}, \dots, P_{o,k}$ وكذلك $w_{o,1}, w_{o,2}, \dots, w_{o,k}$ القيم الممثّلة لهذه الأشياء وأوزانها على الترتيب في دورة الأساس، وكذلك $P_{c,1}, P_{c,2}, \dots, P_{c,k}$ وكذلك $w_{c,1}, w_{c,2}, \dots, w_{c,k}$ القيم الممثّلة لهذه الأشياء وأوزانها على الترتيب في دورة المقارنة. عندئذ القيمة الآتية (والتي سنرمز لها بـ I_F) تدعى **المؤشر المثالي لـ فيشر**:

$$I_F = \sqrt{I_L \cdot I_P} \% \quad [13,6]$$

علماً أن I_P و I_L هما قيمة مؤشري لسبيريس وباشي على الترتيب للمعطيات السابقة.

لاحظ هنا أن المؤشر المثالي لـ فيشر متعلق بمؤشري لسبيريس وباش (المتوسط الهندسي لهما)، ولذلك فإن هذا المؤشر يقيس التغير النسبي بناءً على تكرارات قيم دورة الأساس والمقارنة معاً، وللتوضيح فلو كانت التكرارات هي كميات السلع مثلاً، فعندئذ المؤشر المثالي لـ فيشر يقيس التغير النسبي في تكلفة شراء هذه السلع من الكميات المحدّدة في دورتي الأساس والمقارنة بأن واحد.

(١٣, ٣, ٣, ١) أمثلة

١- بالعودة إلى المثال / ١ / من الأمثلة (١٣, ٢, ١, ٢) (المواد الغذائية المستهلكة من قبل أسرة)، سنفترض علاوة على ما سبق أن الكميات المستهلكة (مقدّرة بـ 100 الكيلو غرام) من السلع المذكورة في العام الآخر (العام 2) أو دورة المقارنة) مقدّمة كما في الجدول (١٣, ٨ أ) حيث وجدنا سابقاً أن لمؤشر لسبيريس القيمة $I_L = 128.95 \%$ ، وكذلك لمؤشر باشي القيمة $I_P = 129.89 \%$ ، ومن ثم يكون للمؤشر المثالي لـ فيشر القيمة الآتية:

$$I_F = \sqrt{I_L \cdot I_P} = \sqrt{128.95 \times 129.89} = 129.42 \%$$

ومن ثم نجد وفقاً للمؤشر المثالي لـ فيشر أن الزيادة في أسعار السلع قد بلغت 29.42%.

٢- بالعودة إلى المثال / ٢ / من الأمثلة (١٣, ٢, ١, ٢) (طلاب الثانوي الذين حصلوا على معدل عام أعلى من 92%)، سنفترض علاوة على ما سبق أن نسب طلاب المرحلة الثانوي الذين حصلوا على معدل عام أعلى من 92% مقدّمة كما في الجدول (٩, ١٣, أ) حيث وجدنا سابقاً أن المؤشر لسيريس القيمة $I_L = 102.94 \%$ ، وكذلك لمؤشر باشي القيمة $I_P = 104.69 \%$ ، ومنه يكون للمؤشر المثالي لـ فيشر القيمة الآتية:

$$I_F = \sqrt{I_L \cdot I_P} = \sqrt{102.94 \times 104.69} = 103.81 \%$$

ومن ثم نجد وفقاً للمؤشر المثالي لـ فيشر أن الزيادة في نسب طلاب المرحلة الثانوي الذين حصلوا على معدل عام أعلى من 92% في الأرياف عن أقرانهم في المدن قد بلغت 3.81%.

٢- بالعودة إلى المثال / ٣ / من الأمثلة (١٣, ٢, ١, ٢) (تقوم شركة تجارية بحملة إعلامية سنوية لترويج منتجاتها)، سنفترض علاوة على ما سبق أن عدد المؤسسات الإعلامية المتعاقد معها في عام 2014 مقدّمة كما في الجدول (١٠, ١٣, أ) حيث وجدنا سابقاً أن المؤشر لسيريس القيمة $I_L = 120 \%$ ، وكذلك لمؤشر باشي القيمة $I_P = 120.5 \%$ ، ومن ثم يكون للمؤشر المثالي لـ فيشر القيمة الآتية:

$$I_F = \sqrt{I_L \cdot I_P} = \sqrt{120 \times 120.5} = 120.25 \%$$

ومن ثم نجد وفقاً للمؤشر المثالي لـ فيشر أن الزيادة في تكاليف الحملة الدعائية قد بلغت 20.25%.

(١٣, ٤) أمثلة

Examples

١- لنفترض أن إحدى المؤسسات العلمية المهتمة بالبيئة تقوم بدراسة التحولات التي تطرأ على كوكب الأرض، واعتمدت من أجل ذلك معايير معيّنة تحدّد من خلالها حالة المنطقة التي خضعت للدراسة أهي: ممتازة، جيدة جداً، جيدة، مقبولة، سيئة، أم سيئة جداً، وأن هذه المؤسسة قد قامت بهذه الدراسة على أربع مناطق متميزة من كوكب الأرض هي: مناطق الغابات، والبادي، والمرتفعات الجبلية، والمناطق القطبية. كذلك سنفترض أنها قامت بهذه الدراسة في فترتين زمنيّتين قبل 50 و 25 سنة وهذا العام أيضاً، وأن النتائج لهذه الدراسة كانت كما في الجدول الآتي:

الجدول (١١, ١٣, أ)

منطقة	حالة المنطقة الآن	حالة المنطقة قبل 25 سنة	حالة المنطقة قبل 50 سنة
غابات	مقبولة	جيدة	جيدة جداً
البادي	سيئة جداً	مقبولة	جيدة
مرتفعات جبلية	مقبولة	جيدة	جيدة جداً
قطبية	سيئة	جيدة	ممتازة

ولننظر ما آلت إليه هذه المناطق على ما كانت عليه قبل 25 سنة مستخدمين في ذلك الأرقام لقياسيّة.

من أجل هذه الدراسة سوف نستخدم الأرقام 6 و 5 و 4 و 3 و 2 و 1 للتعبير عن العبارات: ممتازة، جيدة جداً، جيدة، مقبولة،

سيئة، سيئة جداً على الترتيب. كذلك يُلاحظ أنَّ حالة المناطق قبل 25 سنة ستعتمد كدورة أساس في حين يصبح لدينا دورتي مقارنة هما حالة المناطق قبل 50 سنة، وكذلك حالة المناطق في العام الحالي، ومن ثمَّ يمكننا أن نعرض الجدول الآتي لهذه المعطيات:

الجدول (١١، ١٣. ب)

دورة مقارنة حالة المنطقة قبل 50 سنة	دورة الأساس حالة المنطقة قبل 25 سنة	دورة مقارنة حالة المنطقة الآن	المنطقة	ر.م. <i>i</i>
5	4	3	غابات	1
4	3	2	البوادي	2
5	4	3	مرتفعات جبلية	3
6	4	2	قطبية	4
20	15	10	-----	Total

هذا من جانب ، ومن جانب آخر يُلاحظ أنَّ الأرقام القياسية التي يمكننا استخدامها هنا هي الأرقام القياسية البسيطة فقط (بسبب عدم وجود تكرارات - أوزان - للقيم الممثلة للحالات).

الآن لو أخذنا الفترة قبل 50 سنة كدورة مقارنة فإننا نجد من العلاقة [13,2] أنَّ:

أ- قيمة المؤشر البسيط لمنطقة الغابات تساوي:

$$I_{S,1} = \frac{P_{c,1}}{P_{o,1}} \times 100 = \frac{5}{4} \times 100 = 125 \%$$

وهذا يعني أنَّ حالة الغابات قبل 50 سنة كان أفضل بـ 25% مما كانت عليه قبل 25 سنة، بمعنى أنَّ حالة الغابات قبل 25 سنة قد تردت بنسبة 25% أكثر مما كانت عليه قبل 50 سنة. في الحقيقة نريد أن نبين من خلال هذا الحوار أنَّ ازدياد النسبة عن 100% لا يعني بالضرورة أنَّ شيئاً حسناً قد حصل، وكذلك لتوضيح أنَّ القيم التي نحصل عليها في مثل هذه الدراسات تفهم بشكل نسبي، وتفسيرها يتبع هذه النسبية.

ب- قيمة المؤشر البسيط لمنطقة البوادي تساوي $I_{S,2} = \frac{4}{3} \times 100 = 133.33 \%$ ، وهنا نلاحظ أنَّ حالة البوادي قبل 25 سنة قد تردت بنسبة 33.33% أكثر مما كانت عليه قبل 50 سنة.

ج- منطقة المرتفعات الجبلية تساوي $I_{S,3} = 125 \%$ ، وهنا نلاحظ أنَّ حالة المرتفعات الجبلية قبل 25 سنة قد تردت بنسبة 25% أكثر مما كانت عليه قبل 50 سنة.

د- المنطقة القطبية تساوي $I_{S,4} = 150 \%$ ، وهنا نلاحظ أنَّ حالة القطبية قبل 25 سنة قد تردت بنسبة 50% أكثر مما كانت عليه قبل 50 سنة.

هكذا نجد أنَّ قيمة معدّل المؤشر البسيط لحالات هذه المناطق تساوي:

$$SA := \frac{1}{4} \sum_{i=1}^4 I_{S,i} = \frac{125 + 133.33 + 125 + 150}{4} = \frac{533.33}{4} = 133.333 \%$$

فلاحظ أنَّ حالة المناطق التي قيد الدراسة قبل 25 سنة قد تردت بمعدّل 33.33% أكثر مما كانت عليه قبل 50 سنة.

أما المؤشر الكلي البسيط لحالات هذه المناطق فنجد أنه باستخدام العلاقة [13,3] يساوي:

$$I_C = \frac{20}{15} \times 100 = 133.333 \%$$

وهي ذات القيمة التي حصلنا عليها من أجل قيمة معدل المؤشر البسيط لحالات هذه المناطق. لكن يجب الانتباه هنا إلى أنه ليس بالضرورة أن تكون قيمة معدل المؤشر البسيط تساوي قيمة المؤشر الكلي البسيط.

بشكل مماثل يمكن للقارئ تنفيذ الحسابات السابقة عندما نأخذ حالة المناطق في العام الحالي كدورة مقارنة.

الآن، لنقم بتمديد دراستنا السابقة، وسنفترض أنه خضعت مواقع عديدة من كل منطقة من المناطق التي هي قيد الدراسة، وأن النتائج كانت كما في الجدول الآتي:

الجدول (١١، ١٣ ج)

ر.م. <i>i</i>	المنطقة	دورة الأساس قبل 25 سنة		دورة المقارنة قبل 50 سنة	
		عدد المواقع	حالة المنطقة قبل 25 سنة	عدد المواقع	حالة المنطقة قبل 50 سنة
1	غابات	5	4	6	5
2	البوادي	4	3	3	4
3	مرتفعات جبلية	3	4	5	5
4	قطبية	5	4	4	6
Total	-----	17	15	18	20

ولنقم بحساب قيمة المؤشر المثالي لـ فيشر I_F للمعطيات السابقة.

من أجل ذلك علينا حساب مؤشري لسيريس I_L وباشي I_P ، فنجد باستخدام العلاقتين [13,4] و [13,5] أن:

$$I_L = \frac{86}{64} \times 100 = 134.38 \% \quad \& \quad I_P = \frac{91}{69} \times 100 = 149.18 \%$$

ومنه باستخدام العلاقة [13,6] نجد أن قيمة المؤشر المثالي لـ فيشر تساوي:

$$I_F = \sqrt{I_L \cdot I_P} = \sqrt{134.38 \times 149.18} = 141.59 \%$$

وهذا يشير إلى أن حالة المواقع التي خضعت للدراسة قبل 25 سنة قد تردت بنسبة 41.59% أكثر مما كانت عليه قبل 50 سنة وفقاً للمواقع التي خضعت للدراسة آنذاك.

بشكل مماثل يمكن للقارئ تنفيذ الحسابات السابقة عندما نأخذ حالة المناطق في العام الحالي كدورة مقارنة.

٢- لنفترض أن حكومة دولة ما أرادت تقديم زيادة عامة لرواتب الموظفين في الدولة، ولكي تكون الزيادة منصفة رأت أن قيمة المؤشر المثالي لـ فيشر يعطيها تبصراً جيداً لنسبة الزيادة المقترحة، فقامت بسبر لأسعار متطلبات الحياة المعيشية للمواطنين (مقدراً بـ 100 وحدة نقدية) ولكل متطلب على حدة في عدد من المدن (اختيرت عشوائياً) عند آخر زيادة منحت للموظفين، ومن ثم قامت من أجل كل متطلب على حدة بالنظر في أسعار تلك المتطلبات في العام الحالي لعدد من المدن (اختيرت عشوائياً أيضاً)، فكانت لديها المعطيات الآتية:

الجدول (١٢، ١٣. أ)

م.ر <i>i</i>	المتطلب	دورة الأساس		دورة المقارنة	
		العام الذي تمت فيه آخر زيادة للراتب		العام الحالي	
		عدد المدن الخاضعة للدراسة	متوسط التكلفة الشهري	عدد المدن الخاضعة للدراسة	متوسط التكلفة الشهري
1	المواد الغذائية	8	12	7	20
2	الطاقة	5	5	5	7
3	وسائل النقل	7	8	6	10
4	الطبابة	5	7	8	8
Total	-----	25	32	26	45

الآن لحساب قيمة المؤشر المثالي لـ فيشر I_F للمعطيات السابقة علينا حساب مؤشري لسبيريس I_L و I_P ، فنجد باستخدام العلاقتين [13,4] و [13,5] أنَّ:

$$I_L = \frac{305}{212} \times 100 = 143.87 \% \quad \& \quad I_P = \frac{299}{213} \times 100 = 140.38 \% \quad \%$$

ومنه باستخدام العلاقة [13,6] نجد أنَّ قيمة المؤشر المثالي لـ فيشر تساوي:

$$I_F = \sqrt{I_L \cdot I_P} = \sqrt{143.87 \times 140.38} = 142.11 \%$$

وهذا يشير إلى أنَّ متطلبات الحياة المعيشية للمواطنين في هذا العام قد ازدادت بنسبة 42.11% أكثر مما كانت عليه لدى آخر زيادة للراتب، ولذلك من الممكن أن تقترح زيادة على الرواتب الشهرية للموظفين بنسبة 42.11% من الراتب الأساسي.

لقد ذكرنا سابقاً أنَّه يجب التفكير ملياً عند اختيار دورة الأساس وبشكل خاص عند استخدام المؤشرات الموزونة، فعلى سبيل المثال لو قمنا بعكس الفرضيات السابقة المتعلقة بدورة الأساس فعندئذ سيكون لدينا المعطيات الآتي:

الجدول (١٢، ١٣. ب)

م.ر <i>i</i>	المتطلب	دورة الأساس		دورة مقارنة	
		العام الحالي		العام الذي تمت فيه آخر زيادة للراتب	
		عدد المدن الخاضعة للدراسة	متوسط التكلفة الشهري	عدد المدن الخاضعة للدراسة	متوسط التكلفة الشهري
1	المواد الغذائية	7	20	8	12
2	الطاقة	5	7	5	5
3	وسائل النقل	6	10	7	8
4	الطبابة	8	8	5	7
Total	-----	26	45	25	32

ومن ثمَّ يكون لدينا:

$$I_L = \frac{213}{299} \times 100 = 71.24 \% \quad \& \quad I_P = \frac{212}{305} \times 100 = 69.51 \%$$

ومنه باستخدام العلاقة [13,6] نجد أنَّ قيمة المؤشر المثالي لـ فيشر تساوي:

$$I_F = \sqrt{I_L \cdot I_P} = \sqrt{71.24 \times 69.51} = 70.37 \%$$

وهذا يشير إلى أنَّ متطلبات الحياة المعيشية للمواطنين لدى آخر زيادة للراتب كانت أقل بنسبة 29.76% ممَّا هي عليه في العام الحالي، وهذه القيمة تختلف كثيراً عن القيمة التي حصلنا عليها سابقاً.

هذا ما تيسَّر تقديمه من أجل الجزء النظري والتطبيقي لهذا الفصل

تمارين الفصل الثالث عشر

١- اشترك أربعة أشخاص كل على حدة في البورصة حيث اشترى كل منهم سهماً من شركة ما بمبلغ (مقدّر بوحدة نقدية ما)، ومن ثمّ باعه لاحقاً بقيمة كما في الجدول الآتي:

سعر البيع	سعر الشراء	الشخص	ر.م. i
1600	1500	A	1
1550	1600	B	2
1600	1450	C	3
1500	1550	D	4

والمطلوب ما يلي:

أ- عين دورتي الأساس والمقارنة مع تعليل السبب إن كان هناك تفضيل لأحدهما على الآخر.

ب- احسب المؤشرات البسيطة للمعطيات السابقة.

ج- احسب المؤشر الكلي البسيط للمعطيات السابقة، وماذا تستنتج من ذلك؟

٢- تقدّم ثلاثة متسابقين إلى برنامج مسابقات رياضية مكوّن من مرحلتين، وبحيث يمكن للمتسابق أن يحصل على درجة أقصاها 100%، وعلاوة على ذلك يسمح للمتسابق في المرحلة الأولى أن يجري حتى خمسة تدريبات قبل دخول المسابقة، وبعد الانتهاء من المرحلة الأولى يمكنه دخول المرحلة الثانية دون أية تدريبات مسبقّة. الآن سنفترض أنّ النتائج كانت كما في الجدول الآتي:

الدرجة التي حصل عليها المتدرب في المرحلة الثانية	الدرجة التي حصل عليها المتدرب في المرحلة الأولى	عدد التدريبات السابقة للمرحلة الأولى	المتسابق
75%	85%	4	A
95%	92%	3	B
82%	87%	5	C

والمطلوب ما يلي:

أ- عين دورتي الأساس والمقارنة مع تعليل السبب إن كان هناك تفضيل لأحدهما على الآخر.

ب- احسب المؤشرات البسيطة للمعطيات السابقة.

ج- احسب المؤشر الكلي البسيط للمعطيات السابقة، وماذا تستنتج من ذلك؟

د- إذا اخترنا المرحلة الأولى كدورة أساس، فأی المؤشرات الموزونة صالح للاستخدام في هذه الحالة، ومن ثمّ احسب قيمة هذا المؤشر؟

هـ- إذا اخترنا المرحلة الثانية كدورة أساس، فأی المؤشرات الموزونة صالح للاستخدام في هذه الحالة، ومن ثمّ احسب قيمة هذا المؤشر؟

٣- يقوم بلد باستيراد بعض المواد والسلع وكذلك يصدر من منتجاته مواد وسلعاً مماثلة (كأن يستورد القمح الذي يستخدم لصناعة الخبز ويصدر القمح الذي يستخدم لصناعة البسكويت)، وسنفترض أنّ كمّيات ومتوسط أسعار الطن من هذه المواد والسلع مقدّرة بـ 1000

وحدة نقدية معطاة من خلال الجدول الآتي:

قيمة المادة أو السلعة المستوردة	الكمية	قيمة المادة أو السلعة المصدرة	الكمية	المادة أو السلعة
900	6000	1000	5000	القمح
1100	165	1250	250	الذرة
6500	15	5000	20	الملابس
32000	15	25000	12	الأدوية

والمطلوب ما يلي:

أ- عين دورتي الأساس والمقارنة مع تعليل السبب إن كان هناك تفضيل لأحدهما على الآخر.

ب- احسب المؤشرات البسيطة للمعطيات السابقة.

ج- احسب المؤشر الكلي البسيط للمعطيات السابقة، وماذا تستنتج من ذلك؟

د- احسب المؤشر المثالي لـ فيشر من أجل المعطيات السابقة، وماذا تستنتج من ذلك؟

٤- لنفترض أن إحدى المؤسسات العلمية المهتمة بالبيئة تقوم بدراسة التلوث في داخل المدن معتمدة في ذلك معايير معينة تحدد من خلالها نسبة التلوث، وأن دراستها شملت عدداً من المدن، فإذا قامت بهذه الدراسة في فصلي الشتاء والصيف من عام ما، وأن النتائج كانت كما في الجدول الآتي:

م.ر <i>i</i>	الشيء الخاضع للدراسة	في الصيف		في الشتاء	
		عدد المدن الخاضعة للدراسة	نسبة التلوث	عدد المدن الخاضعة للدراسة	نسبة التلوث
1	الهواء	9	67%	8	75%
2	الماء	7	12%	8	15%
3	التربة	12	1.5%	12	2%
4	الضجيج	8	78%	9	65%
Total	-----				

والمطلوب ما يلي:

أ- عين دورتي الأساس والمقارنة مع تعليل السبب إن كان هناك تفضيل لأحدهما على الآخر.

ب- احسب المؤشرات البسيطة للمعطيات السابقة.

ج- احسب المؤشر الكلي البسيط للمعطيات السابقة، وماذا تستنتج من ذلك؟

د- احسب المؤشر المثالي لـ فيشر من أجل المعطيات السابقة، وماذا تستنتج من ذلك؟

٥- لنفترض أنَّ أحد المصانع المنتجة للإسمنت تقوم بدراسة حول تأثير الخرسانة المصنَّعة من هذا الاسمنت في مناطق مختلفة بدرجة رطوبتها (تختلف فيما بينها بقيمة متوسط الرطوبة السنوية لها) معتمدة في ذلك معايير معيَّنة لقياس التلف الناتج عن الرطوبة في كل متر مكعب من الخرسانة بعد مرور فترة من زمن استخدامها (مقدَّرة بالسنة)، وأنَّ دراستها شملت عدداً من المناطق، فإذا قامت بهذه الدراسة في فترتين من الزمن (بعد مرور عشر سنوات، وبعد مرور خمسة عشر سنة)، وأنَّ النتائج كانت كما في الجدول الآتي:

٢٠٠٠ <i>i</i>	المنطقة الخاضعة للدراصة	بعد مرور عشر سنوات		بعد مرور خمسة عشر سنة	
		عدد المناطق الخاضعة للدراصة	النسبة المئوية للتلف في المتر المكعب من الخرسانة	عدد المناطق الخاضعة للدراصة	النسبة المئوية للتلف في المتر المكعب من الخرسانة
1	الساحل	12	23%	14	58%
2	المرتفعات الجبلية	10	15%	8	37%
3	الداخلية التي على ارتفاع ما بين 400 وحتى 700 متر عن سطح البحر	26	2%	32	5%
Total	-----				

والمطلوب ما يلي:

- أ- عين دورتي الأساس والمقارنة مع تعليل السبب إن كان هناك تفضيل لأحدهما على الآخر.
- ب- احسب المؤشَّرات البسيطة للمُعْطيات السابقة.
- ج- احسب المؤشِّر الكلي البسيط للمُعْطيات السابقة، وماذا تستنتج من ذلك؟
- د- احسب المؤشِّر المثالي لـ فيشر من أجل المُعطيات السابقة، وماذا تستنتج من ذلك؟

الملحق (A)

رموز ومصطلحات استخدمت في الكتاب

الرمز	دلالة الرمز ومعناه
$:=$	يعني "يساوي بالتعريف" وقد كان العاملون في مجال الكوبرنيتك هم أول من استخدم هذا الرمز.
$\hat{=}$	يعني "يساوي اصطلاحاً"، بمعنى أنّ ما سيأتي بعده هو تعبير اصطلاحى سنعتمده لما يسبقه من مقادير أو صيغ.
$;$	داخل الأقواس الممثلة للمجموعات والحوادث للتعبير عن العبارة "وذلك لكل" أو بمعنى "وذلك من أجل" حسب الدلالة المناسبة لها.
$:$	داخل الأقواس الممثلة للمجموعات والحوادث للتعبير عن العبارة "علماً أنّ".
$ $	للتعبير عن الصيغ الشرطية في دراسة الاحتمالات الشرطية.
$\mathbb{N} := \{1, 2, 3, \dots\}$	مجموعة الأعداد الطبيعية Natural Numbers
$\mathbb{N}^o := \mathbb{N} \cup \{0\}$	مجموعة الأعداد الطبيعية مع الصفر Whole Numbers
$\bar{\mathbb{N}} := \mathbb{N}^o \cup \{+\infty\}$	مجموعة الأعداد الطبيعية الموسّعة Extended Natural Numbers
$\mathbb{N}_n := \{1, 2, 3, \dots, n\}$	علماً أنّ $n \in \mathbb{N}$ كفي و لكن مُثبت.
\mathbb{Z}	مجموعة الأعداد الصحيحة Integer Number
\mathbb{Q}	مجموعة الأعداد النسبية Rational Numbers
\mathbb{R}	مجموعة الأعداد الحقيقية Real Number
$\mathbb{R}^* := \mathbb{R} \setminus \{0\}$	مجموعة الأعداد الحقيقية ما عدا الصفر
$\mathbb{R}^+ := \mathbb{R} \setminus (-\infty, 0]$	مجموعة الأعداد الحقيقية الموجبة

الرمز	دلالة الرمز ومعناه
$\bar{\mathbb{R}} = \mathbb{R} \cup \{-\infty, +\infty\}$	مجموعة الأعداد الحقيقية الموسَّعة
\mathbb{C}	مجموعة الأعداد العقدية (أو المركَّبة) Complex Number
$\lceil x \rceil$	يشير إلى أصغر عدد صحيح أكبر أو يساوي x ، فعلى سبيل المثال: $\lceil 8 \rceil = 8 \quad \& \quad \lceil 8.11 \rceil = 9 \quad \& \quad \lceil 8.99 \rceil = 9$
$\lfloor x \rfloor$	يشير إلى أكبر عدد صحيح أصغر أو يساوي x ، فعلى سبيل المثال: $\lfloor 8 \rfloor = 8 \quad \& \quad \lfloor 8.11 \rfloor = 8 \quad \& \quad \lfloor 8.99 \rfloor = 8$
$a \ll b$	يعني أنَّ b أكبر بكثير من a ، علماً أنَّ a و b عددين حقيقيين.
$1 \ll a$	يعني أنَّ a كبيراً بقدر كافٍ، علماً أنَّ a عدد حقيقي موجب.
$1 \gg a$	يعني أنَّ a صغيراً بقدر كافٍ، علماً أنَّ a عدد حقيقي موجب.
\wedge	الرمز المنطقي الذي يشير إلى عبارة (و and).
\vee	الرمز المنطقي الذي يشير إلى عبارة (أو or).
\circ	يشير إلى تركيب التطبيقات (أو الدوال).
$\lambda \prec \mu$	يعني الاستمرار المطلق بين قياسين λ و μ فوق فضاء مقيس.
$\mathbb{Z}_1 \supset \mathbb{Z}_2$	يعني أنَّ التجزئة \mathbb{Z}_1 أنعم من التجزئة \mathbb{Z}_2 .

مفاهيم عامة من الرياضيات

نقدم فيما يلي بعض المفاهيم والمصطلحات الرياضية التي استخدمت في فصول هذا الكتاب وذلك بغية التذكير بها، لأنه من المفترض أن يكون القارئ ملماً بها قبل دراسة هذا الكتاب. إن البراهين والإثباتات الخاصة بفقرات هذا الملحق تم تجاوزها حيث يمكن لمن يود الاطلاع عليها الرجوع إلى المراجع ذات الصلة ومنها [1] و [16] و [23] في فهرس المراجع لهذا الكتاب.

A-1 - المجموعات

من المعلوم أن مفهوم المجموعة يُعدّ من الأهمية بمكان في مجال الرياضيات عامة بحيث إنه يأتي بالمرتبة الثانية من حيث الأهمية بعد مفهوم الأعداد، ولكننا سوف نستعرض (وبشكل موجز) جانباً يسيراً من نظرية المجموعات مع التركيز على المواضيع التي كانت موضع اهتمامنا في هذا الكتاب، علماً أننا سنستخدم ما اتفق عليه فقط دون الخوض في تفصيلات المسائل وبراهينها.

A-1-1 - تعريف (المجموعة Set)

المجموعة هي أي تجمع لأشياء محدّدة ومتمايزة جيداً بحسب حدسنا أو تفكيرنا، وصُغت في قالب موحد.

هذا التعريف للمجموعة كان قد قُدّم من قبل الرياضي الألماني **كانتور** (Georg Cantor (1845-1918) الذي أسس نظرية المجموعات Sets Theory.

إنّ الأشياء المكوّنة للمجموعة تُدعى عناصر، وقد درجت العادة على أن يُرمز للمجموعات بحروف لاتينية كبيرة من قبيل A ، B ، C ، ...، أو بأحرف إغريقية كبيرة من قبيل Ω ، Λ ، Θ ، ...، وأما عناصر المجموعات فيرمز لها بأحرف لاتينية صغيرة من قبيل a ، b ، c ، ...، أو بأحرف إغريقية صغيرة من قبيل α ، β ، γ ، ...

في الحقيقة إنّ التعريف السابق هو التعريف العام للمجموعة، حيث يُطلق على المجموعة المنوّه عنها آنفاً اسم **المجموعة الشاملة**، ولكن توجد طرائق عديدة لعرض المجموعات يفترض أن تكون معلومة لدى القارئ (لأنّها تدرّس في مرحلة التعليم قبل الجامعي)، ولذلك سنفترض أنّ القارئ ملّم بالقضايا المتعلقة بالمجموعات (مثل طرائق عرضها، والعمليات الجبرية على المجموعات، وطرائق تمثيلها بيانياً و...) التي تدرّس في مراحل التعليم السابقة للتعليم الجامعي (مرحلة التعليم الأساسي والثانوية)، وما سنقوم بتقديمه هنا سيكون على سبيل التذكير فقط.

الآن بفرض أنّ Ω مجموعة شاملة، فعندئذ مجموعة العناصر A من Ω التي تتمتع بصفة محدّدة تدعى **مجموعات جزئية**، وفي حال كانت هذه المجموعة لا تحوي أي عنصر فحينئذ تدعى **مجموعة خالية** ويرمز لها بـ \emptyset ، ومن ثمّ نلاحظ أنّ المجموعة الخالية محتواة في أي مجموعة. كذلك بفرض أنّ $\Omega \supseteq B$ عندئذ يطلق على مجموعة العناصر التي تنتمي إلى Ω ولا تنتمي إلى B اسم **المجموعة المتممة** لـ B ويرمز لها بـ \bar{B} .

A-1-2 - تعريف (قدرة مجموعة Set Cardinality)

لتكن A مجموعة ما من مجموعة شاملة Ω ، فعندئذ تُعرّف **قدرة** A على أنّها عدد عناصرها، ويرمز لهذا العدد بـ $|A|$ ، فإذا كان لدينا على سبيل المثال $A = \{a_1, a_2, \dots, a_n\}$ مع $n \in \mathbb{N}$ مثبت، فإنّه سيكون لدينا $|A| = n$ ، وأما إذا كانت A غير منتهية فعندئذ نُميّز بين حالتين:

الأولى: إذا كانت A غير منتهية ولكن يمكن إيجاد تطبيق تقابل σ من \mathbb{N} على A ، فعندئذ يُقال إن المجموعة A **قابلة للعد** Countable Set، ويكتب $|A| = \infty$. إن التعبير السابق يعني أنه يمكن ترقيم عناصر المجموعة A بوساطة الأعداد الطبيعية \mathbb{N} .

الثانية: إذا كانت A غير منتهية ولكن يمكن إيجاد تطبيق تقابل σ من \mathbb{R} على A ، فعندئذ يُقال إن المجموعة A **غير قابلة للعد** Uncountable Set، ويُطلق على قدرتها اسم **قدرة المستمر** ورمزها \mathfrak{c} أي إن $|\mathbb{R}| = \mathfrak{c}$ ، ولذلك يكتب $|A| = \mathfrak{c}$. بناء على ما سبق يمكننا أن نذكر بالآتي:

- إذا وجد تطبيق تقابل σ بين مجموعتين A و B ، فعندئذ يُقال إن A **تكافئ** B أو إن $A \sim B$ **متكافئتان**، ويكتب حينئذ $A \sim B$.
- إذا حُذفت مجموعة منتهية من مجموعة قابلة للعد فإن الباقي هي مجموعة قابلة للعد أيضاً.
- إذا حُذفت مجموعة منتهية من مجموعة غير قابلة للعد فإن الباقي هي مجموعة غير قابلة للعد أيضاً.
- إذا حُذفت مجموعة قابلة للعد من مجموعة غير قابلة للعد فإن الباقي هو مجموعة غير قابلة للعد أيضاً.
- إن المجموعة الناتجة عن اتحاد (أو اجتماع) عدد من المجموعات قابلة للعد هي من جديد مجموعة قابلة للعد.
- لتكن A مجموعة غير منتهية ولكنها قابلة للعد على الأكثر، فعندئذ تكون أسرة كل المجموعات الجزئية من A (**ويرمز لها بـ** 2^A) هي مجموعة غير قابلة للعد.
- إذا كانت A_1, A_2, \dots, A_n مجموعات قابلة للعد مع $n \in \mathbb{N}$ كفي ولكن مثبت، فإن المجموعة $B = A_1 \times A_2 \times \dots \times A_n$ تكون قابلة للعد أيضاً.

A-1-3 - العمليات الجبرية على المجموعات

لتكن A و B مجموعتين من مجموعة شاملة Ω ، فعندئذ:

- ١- **اتحاد** المجموعتين A و B هي مجموعة كل العناصر التي تنتمي إلى A أو إلى B أو إلى كليهما معاً، ويرمز لها بـ $A \cup B$ ، علماً أن عبارة (أو) هنا لا تفيد الحصر. أي إنه لدينا:

$$A \cup B = \{\omega \in \Omega ; \omega \in A \text{ or } \omega \in B\}$$

وإذا كانت المجموعات A_1, A_2, \dots, A_n منفصلة مثني مثني فإنه يمكن استخدام الرمز $\sum_{i=1}^n A_i$ بدلاً من $\bigcup_{i=1}^n A_i$ للدلالة على أن المجموعات التي تحت رمز الاتحاد منفصلة مثني مثني.

- ٢- **تقاطع** المجموعتين A و B هي مجموعة كل العناصر التي تنتمي إلى كل من A و B معاً، ويرمز لها بـ $A \cap B$. أي إنه لدينا:

$$A \cap B = \{\omega \in \Omega ; \omega \in A \text{ and } \omega \in B\}$$

- ٣- **الفرق** الناتج عن طرح المجموعة A من B (**ويقال A ناقص B**) هي مجموعة كل العناصر التي تنتمي إلى A ولا تنتمي إلى B ، ويرمز لها بـ $A \setminus B$. أي إنه لدينا:

$$A \setminus B := \{\omega \in \Omega ; \omega \in A \text{ and } \omega \notin B\}$$

- ٤- **الفرق التناظري** بين A و B هي مجموعة كل العناصر من A و B ولا تنتمي إلى $A \cap B$ ، ويرمز له بـ $A \Delta B$ ، أي إنه لدينا:

$$A \Delta B = (A \cup B) \setminus (A \cap B)$$

الآن، لتكن Ω مجموعة شاملة، ولنفترض أن A, B, C مجموعات جزئية من Ω ، فعندئذ يمكن للقارئ التحقق من صحة

العلاقات الآتية:

- a) $A \cup B = B \cup A$ & $A \cap B = B \cap A$
b) $(A \cup B) \cup C = A \cup (B \cup C)$ & $(A \cap B) \cap C = A \cap (B \cap C)$
c) $A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$ & $A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$
d) $A \cap (B \setminus C) = (A \cap B) \setminus (A \cap C) = (A \cap B) \setminus C$
e) $\overline{A \cup B} = \bar{A} \cap \bar{B}$ & $\overline{A \cap B} = \bar{A} \cup \bar{B}$ قانون دي مورغان

وهاتين العلاقتين الأخيرتين تبقيان ساريتا المفعول من أجل أي عدد منته أو غير منته (ولكن قابل للعد) من المجموعات، أي إنه من أجل أي متتالية مجموعات $A_1, A_2, \dots, A_n, \dots$ من مجموعة شاملة Ω ، يكون لدينا:

- f) $\overline{\bigcup_{n=1}^{\infty} A_n} = \bigcap_{n=1}^{\infty} \bar{A}_n$ & $\overline{\bigcap_{n=1}^{\infty} A_n} = \bigcup_{n=1}^{\infty} \bar{A}_n$
g) $A \setminus B = A \cap \bar{B}$ & $A \setminus \bar{B} = A \cap B$ & $(A \setminus B) \cup (B \setminus A) = (A \cap \bar{B}) \cup (B \cap \bar{A})$

وكذلك إذا كانت $B \supseteq A$ فعندئذ يكون لدينا:

- h) $\begin{cases} \bar{B} \subseteq \bar{A} & \& A \cap B = A \\ A \cup B = B & \& B \setminus A = \bar{A} \setminus \bar{B} \end{cases}$

A-1-4 - متتاليات المجموعات المطردة:

لتكن $(A_n)_{n \in \mathbb{N}}$ متتالية مجموعات من مجموعة شاملة Ω ، فإذا كان:

- ١- لدينا $A_1 \supseteq A_2 \supseteq \dots \supseteq A_n \supseteq \dots$ فإنه يُقال عن المتتالية $(A_n)_{n \in \mathbb{N}}$ إنها متتالية مجموعات غير متناقصة.
 - ٢- لدينا $A_1 \supset A_2 \supset \dots \supset A_n \supset \dots$ فإنه يُقال عن المتتالية $(A_n)_{n \in \mathbb{N}}$ إنها متتالية مجموعات متزايدة.
 - ٣- لدينا $A_1 \subseteq A_2 \subseteq \dots \subseteq A_n \subseteq \dots$ فإنه يُقال عن المتتالية $(A_n)_{n \in \mathbb{N}}$ إنها متتالية مجموعات غير متزايدة.
 - ٤- لدينا $A_1 \subset A_2 \subset \dots \subset A_n \subset \dots$ فإنه يُقال عن المتتالية $(A_n)_{n \in \mathbb{N}}$ إنها متتالية مجموعات متناقصة.
- علمًا أنه إذا وافقت المتتالية $(A_n)_{n \in \mathbb{N}}$ إحدى الحالات الأربع السابقة فعندئذ يُقال عن هذه المتتالية إنها **مطرّدة**.

A-1-5 - تقارب متتاليات المجموعات

لتكن $(A_n)_{n \in \mathbb{N}}$ متتالية مجموعات من مجموعة شاملة Ω ، فعندئذ:

- ١- إذا كانت $(A_n)_{n \in \mathbb{N}}$ غير متناقصة (أو متزايدة تمامًا) فإن نهاية هذه المتتالية (ولتكن مجموعة A) هو اتحاد عناصرها، أي إن:

$$A = \lim_{n \rightarrow \infty} A_n = \bigcup_{n=1}^{\infty} A_n \quad \text{or} \quad A = \lim_{n \uparrow \infty} A_n = \bigcup_{n=1}^{\infty} A_n$$

- ٢- إذا كانت $(A_n)_{n \in \mathbb{N}}$ غير متزايدة (أو متناقصة تمامًا) فإن نهاية هذه المتتالية (ولتكن مجموعة A) هو تقاطع عناصرها، أي إن:

$$A = \lim_{n \rightarrow \infty} A_n = \bigcap_{n=1}^{\infty} A_n \quad \text{or} \quad A = \lim_{n \downarrow \infty} A_n = \bigcap_{n=1}^{\infty} A_n$$

٣- تُعرّف النهاية العليا للمتتالية $(A_n)_{n \in \mathbb{N}}$ (في حال وجودها) على أنها المجموعة $A = \bigcap_{n=1}^{\infty} \bigcup_{k=n}^{\infty} A_k$ ، ويكتب حينئذ:

$$A = \overline{\lim}_{n \rightarrow \infty} A_n = \limsup A_n = \bigcap_{n=1}^{\infty} \bigcup_{k=n}^{\infty} A_k$$

٤- تُعرّف النهاية الدنيا لهذه المتتالية $(A_n)_{n \in \mathbb{N}}$ (في حال وجودها) على أنها المجموعة $A = \bigcup_{n=1}^{\infty} \bigcap_{k=n}^{\infty} A_k$ ، ويكتب حينئذ:

$$A = \underline{\lim}_{n \rightarrow \infty} A_n = \liminf A_n = \bigcup_{n=1}^{\infty} \bigcap_{k=n}^{\infty} A_k$$

وبناءً على ما سبق يمكن البرهنة على صحة العلاقات الآتية:

- a) $\overline{\limsup A_n} = \liminf \overline{A_n}$ & $\overline{\liminf A_n} = \limsup \overline{A_n}$
- b) $\liminf A_n \subseteq \limsup A_n$
- c) $\limsup (A_n \cup B_n) = \limsup A_n \cup \limsup B_n$
- d) $\limsup A_n \cap \liminf B_n \subseteq \limsup (A_n \cap B_n) \subseteq \limsup A_n \cap \limsup B_n$

علماً أن الخط العلوي يرمز إلى التّمم، وفي الحالة الخاصة عندما تكون المتتالية $(A_n)_{n \in \mathbb{N}}$ مطّردة ومتقاربة من مجموعة A فإنه يكون لدينا:

$$e) \liminf A_n = \limsup A_n = A$$

A-١-٥ - تعريف (المجموعة المحدبة Convex Set)

يقال عن مجموعة $D \subseteq \mathbb{R}^n$ إنها محدبة إذا كان من أجل كل $\vec{x}_n = (x_1, x_2, \dots, x_n)$ و $\vec{y}_n = (y_1, y_2, \dots, y_n)$ من D ، ومن أجل أي $0 \leq \theta \leq 1$ لدينا العلاقة الآتية محققة:

$$\theta \cdot \vec{x}_n + (1 - \theta) \cdot \vec{y}_n \in D$$

وفي الحالة الخاصة لو أخذنا $\mathbb{R}^2 \supseteq D$ فإنه إذا كان المستقيم الواصل بين أية نقطتين من D يقع بكامله في D أيضاً، فعندئذ يُقال عن المجموعة D إنها محدبة.



A-٢ - مفاهيم من التحليل المزجي (التوافقي)

A-٢-١ - تعريف (التباديل Permutations)

لتكن A و B مجموعتين منتهيتين قدرة كل منهما تساوي n ، فعندئذ كل تطبيق تقابل $\pi: A \longleftrightarrow B$ يدعى تبديلاً لعناصر المجموعة A وفقاً لعناصر المجموعة B .

إن مجموعة كل تبديل عناصر B وفقاً لعناصر A سنرمز لها بـ $\Pi_{A,B}$ ، ومن أجل $A=B$ سنكتب Π_A عوضاً عن $\Pi_{A,A}$ ، وفي الحالة الخاصة عندما يكون لدينا $A = \mathbb{N}_n$ مع $n \in \mathbb{N}$ فإننا سنكتب Π_n عوضاً عن $\Pi_{\mathbb{N}_n}$.
بناءً على التعريف السابق يكون من أجل $|A| = |B| = n$ لدينا $|\Pi_{A,B}| = n!$ ، ومن المفيد في كثير من الحالات استخدام **نشر سترلنغ** Stirling Expansion (نسبة إلى الرياضي الأسكتلندي سترلنغ (James Stirling (1692-1770) لحساب المقدار $n!$ باستخدام العلاقة الآتية:

$$n! = \sqrt{2n\pi} n^n e^{-n} e^{\frac{\theta}{12n}} ; n \in \mathbb{N} \text{ \& } 0 < \theta < 1$$

وعندما تكون n كبيرة بقدر كافٍ يمكننا أن نكتب وبتقريب جيد ما يلي:

$$n! \approx \sqrt{2\pi n} n^n e^{-n} ; n \in \mathbb{N}$$

إذا وجدت في المجموعة B عناصر متماثلة كأن يكون فيها n_1 عنصر من نوع أول، و n_2 عنصر من نوع ثاني، و... و n_k عنصر من نوع أخير، وبحيث يكون $\sum_{i=1}^k n_i = n$ ، فعندئذ يكون عدد التباديل في المجموعة $\Pi_{A,B}$ يساوي:

$$\left(\begin{matrix} n \\ n_1, n_2, \dots, n_k \end{matrix} \right) \triangleq \frac{n!}{n_1! \cdot n_2! \cdot \dots \cdot n_k!}$$

يقال عن تبديل $\pi \in \Pi_{\mathbb{N}}$ إنه **تبديل منته** Finite Permutation إذا وجد عدد منته من القيم $j \in \mathbb{N}$ من أجلها لدينا $\pi(j) \neq j$. أي إنه من أجل كل $n \in \mathbb{N}$ لدينا $\pi(n) = n$ باستثناء عدد منته من هذه القيم n .

A-2-2- تعريف (الترتيب)

لتكن A و B مجموعتين منتهيتين بحيث إن $|A| = k$ و $|B| = n$ مع $n \geq k$ ، فعندئذ يُسمي كل تطبيق متباين (تطبيق واحد لواحد) $\zeta: A \rightarrow B$ ترتيباً لعناصر المجموعة B وفقاً لعناصر المجموعة A ، فإذا رمزنا لمجموعة ترتيبات المجموعة B وفقاً لعناصر A بـ $\vartheta_{A,B}$ ، فعندئذ يكون لدينا:

$$|\vartheta_{A,B}| = n \cdot (n-1) \cdot \dots \cdot [n - (k-1)] = \frac{n!}{(n-k)!} \triangleq n P k$$

وفي الحالة الخاصة عندما $k = n$ فإن الترتيب تؤول إلى التباديل التي قُدمت سابقاً ويكون لدينا في هذه الحالة $n P n = n!$.

A-2-3- تعريف (التوافيق Combinations)

لتكن A و B مجموعتين منتهيتين بحيث $|A| = k$ و $|B| = n$ مع $n \geq k$ ، وليكن $\beta: A \rightarrow B$ تطبيقاً متبايناً، فإذا كان المتجه $B \times B \times \dots \times B = B^k \ni \forall$ يحقق العلاقة الآتية من أجل أي تبديل $\pi \in \Pi_k$:

$$(\beta(a_{\pi(1)}), \beta(a_{\pi(2)}), \dots, \beta(a_{\pi(k)})) = (\beta(a_1), \beta(a_2), \dots, \beta(a_k)) = \forall$$

فعندئذ يُسمي التطبيق β توفيقاً لعناصر المجموعة B وفقاً لعناصر المجموعة A .

سنرمز لمجموعة كل التوافيق لعناصر B وفقاً لعناصر A بـ $\mathcal{C}_{A,B}$ ، وإذا كان لدينا $|A| = k$ و $|B| = n$ مع $n \geq k$ ، فإنه سيكون لدينا:

$$|\mathcal{C}_{A,B}| = \frac{n!}{k!(n-k)!} \triangleq \left(\begin{matrix} n \\ k \end{matrix} \right)$$

وذلك بسبب إزالة خاصية أهمية الترتيب التي عدد حالاتها الممكنة يساوي $k!$ ، وفي الحالة الخاصة عندما $k = n$ فإن مفهوم التوافيق يفقد معناه، وذلك لأنه سيصبح لدينا $|\mathcal{C}_{A,B}| = 1$.

A-٣ - القاعدتان الأساسيتان للعد:**A-٣-١ - قاعدة الضرب Multiplication Rule:**

لتكن A و B مجموعتين منتهيتين بقدرة n و m على الترتيب، فعندئذ تكون قدرة المجموعة الناتجة عن الضرب (أو الجداء) الديكارتي لهما $A \times B$ تساوي $n \cdot m$ ، وهذه النتيجة يمكن تعميمها على أي عدد منته من المجموعات المنتهية، فإذا كان لدينا A_1, A_2, \dots, A_k مجموعات منتهية بقدرات n_1, n_2, \dots, n_k على الترتيب، فإن قدرة المجموعة $A_1 \times A_2 \times \dots \times A_k$ ستكون مساوية إلى $n_1 \cdot n_2 \cdot \dots \cdot n_k$ ، أي إنه لدينا $\left| \prod_{i=1}^k A_i \right| = \prod_{i=1}^k n_i$ ، وهذه القاعدة تُعرف باسم **قاعدة الضرب**.

A-٣-١ - قاعدة الجمع Addition Rule:

لتكن A و B مجموعتين منتهيتين بقدرات n و m على الترتيب، فإذا كان لدينا $A \cap B = \emptyset$ فإن قدرة المجموعة $A \cup B$ ستكون مساوية لـ $n + m$ ، وهذه النتيجة يمكن تعميمها على أي عدد منته من المجموعات المنتهية، فإذا كانت A_1, A_2, \dots, A_k مجموعات غير خالية ومنفصلة مثنى مثنى بقدرات n_1, n_2, \dots, n_k على الترتيب، فإن قدرة المجموعة $B = \sum_{i=1}^k A_i$ تساوي $\sum_{i=1}^k n_i$ ، أي إنه لدينا $\left| \sum_{i=1}^k A_i \right| = \sum_{i=1}^k n_i$ ، إن هذه القاعدة تُعرف باسم **قاعدة الجمع**.

A-٤ دوال بمواصفات خاصة

أخيراً نقدم بعض الدوال الخاصة التي ورد ذكرها في دراستنا لهذا الكتاب.

A-٤-١ - تعريف (الدالة المميزة لمجموعة Indicator Function of a Set)

لتكن Ω مجموعة ما غير خالية، ولناخذ $\Omega \supseteq A$ مجموعة جزئية، ولنعرّف من أجل هذه المجموعة دالة حقيقية I_A على Ω كما يلي:

$$I_A(\omega) = \begin{cases} 1 & \text{for } \omega \in A \\ 0 & \text{for } \omega \notin A \end{cases}$$

فعندئذ تدعى I_A **الدالة المميزة للمجموعة A** ، وذلك لأنها تتميز عناصر المجموعة A بشكل تام.

A-٤-١-١ - خصائص الدالة المميزة لمجموعة

نظراً لأهمية الدالة I_A سنقدم بعض خصائصها حيث يمكن للقارئ التحقق من صحتها:

- $I_\Omega(\omega) = 1$; $\forall \omega \in \Omega$
- $I_\emptyset(\omega) = 0$; $\forall \omega \in \Omega$
- For $A, B \subseteq \Omega$ we have $I_{A \cap B}(\omega) = I_A(\omega) \cdot I_B(\omega)$; $\forall \omega \in \Omega$
- For $A, B \subseteq \Omega$ we have $I_{A \cup B}(\omega) = I_A(\omega) + I_B(\omega) - I_{A \cap B}(\omega)$; $\forall \omega \in \Omega$
- For $A, B \subseteq \Omega$ we have $I_{A \Delta B}(\omega) = (I_A(\omega) - I_B(\omega))^2$; $\forall \omega \in \Omega$

A-٤-٢- تعريف (الدالة المحدبة Convex Function)

لتكن $f: D \rightarrow \mathbb{R}$ دالة مُعطاة مع $R^n \supseteq D$ مجموعة محدبة، فإذا كان من أجل أي $0 \leq \theta \leq 1$ وكل $\vec{x}_n = (x_1, x_2, \dots, x_n)$ و $\vec{y}_n = (y_1, y_2, \dots, y_n)$ من D لدينا العلاقة الآتية مُحَقَّقة:

$$f(\theta \cdot \vec{x}_n + (1-\theta) \cdot \vec{y}_n) \leq \theta \cdot f(\vec{x}_n) + (1-\theta) \cdot f(\vec{y}_n)$$

فعندئذ يُقال عن الدالة f إنها محدبة، وإذا كانت العلاقة الآتية مُحَقَّقة من أجل كل $\vec{x}_n \neq \vec{y}_n$:

$$f(\theta \cdot \vec{x}_n + (1-\theta) \cdot \vec{y}_n) < \theta \cdot f(\vec{x}_n) + (1-\theta) \cdot f(\vec{y}_n)$$

فعندئذ يُقال عن الدالة f إنها محدبة على نحو صارم.

من النماذج الشهيرة للدوال الحقيقية المعرفة على $R \supseteq D$ والتي تتمتع بخاصة التحذب نورد الدوال الآتية:

- الدوال الخطية $f(x) = a + bx$ مع a و b من R .

- الدوال الأسية $f(x) = e^{bx}$ مع b من R .

- دوال القوى $f(x) = x^\alpha$ من أجل $R^+ \supseteq D$ و $1 \leq \alpha$ أو $0 \geq \alpha$.

- دوال القيمة المطلقة $f(x) = |x|^p$ من أجل $1 \leq p$.

A-٤-٣- تعريف (الدالة المقعرة Concave Function)

يقال عن دالة حقيقية f معرفة على مجموعة $R^n \supseteq D$ إنها مقعرة إذا كانت الدالة $-f$ محدبة، وفي حال كانت الدالة $-f$ محدبة على نحو صارم، فعندئذ يُقال عن الدالة f إنها مقعرة على نحو صارم.

من النماذج الشهيرة للدوال الحقيقية المعرفة على $R \supseteq D$ التي تتمتع بخاصة التقعر نورد الدوال الآتية:

- الدوال الخطية $f(x) = a + bx$ مع a و b من R ، ومن ثم نلاحظ أن الدوال الخطية هي دوال محدبة ومقعرة بآن واحد.

- دوال القوى $f(x) = x^\alpha$ من أجل $R^+ \supseteq D$ و $0 \leq \alpha \leq 1$.

- الدوال اللوغاريتمية $f(x) = \log x$ من أجل $R^+ \supseteq D$.

A-٤-٤- تعريف (الدالة الدرجية Step Function)

لتكن $f: D \rightarrow \mathbb{R}$ دالة مُعطاة مع $R \supseteq D$ ، فإذا كان من أجل $n \in \mathbb{N}$ (مُشَبَّه) يوجد a_1, a_2, \dots, a_n و A_1, A_2, \dots, A_n بحيث يكون للدالة f العرض الآتي:

$$f(x) = \sum_{k=1}^n a_k \cdot \mathbf{I}_{A_k}(x)$$

فعندئذ يُقال عن الدالة f إنها دالة درجية Step Function أو دالة بسيطة Simple Function.

A-٤-٥- بعض الخصائص الجبرية للدوال الدرجية

١- بفرض أن f و g دالتان درجيتان معرفتان على مجموعة $R \supseteq D$ ، فعندئذ:

أ- من أجل أي $\alpha \in R^*$ تكون الدالة $\alpha \cdot f$ درجية على D أيضاً.

ب- تكون الدوال $f \pm g$ و $f \cdot g$ هي دوال درجية على D أيضاً.

٢- من أجل أية دالة حقيقية f معرفة ومطردة على المجموعة D توجد متتالية دوال درجية $(f_n)_{n \in \mathbb{N}}$ معرفة على D بحيث يكون لدينا:

$$f(x) = \lim_{n \rightarrow \infty} f_n(x) \quad ; \forall x \in D$$

٣- من أجل أية دالة حقيقية f معرفة ومستمرة على المجموعة D توجد متتالية دوال درجية $(f_n)_{n \in \mathbb{N}}$ معرفة على D بحيث يكون لدينا:

$$f(x) = \lim_{n \rightarrow \infty} f_n(x) \quad ; \forall x \in D$$

A-٤-٦ - تعريف (دالة غاما Gama Function)

لتكن Γ دالة حقيقية معرفة على الفترة $(0, \infty)$ من خلال:

$$\Gamma(x) := \int_0^{+\infty} y^{x-1} e^{-y} dy$$

فعندئذ هذه الدالة تُدعى **دالة غاما**.

يمكن البرهنة على أن هذه الدالة تتمتع بالخصائص الآتية:

- الدالة $\Gamma(x)$ مستمرة وقابلة للاشتقاق عدداً كبيراً من المرات على مجالها (**مجموعة تعريفها**)، ومن أجل كل $x \in (0, \infty)$ لدينا العلاقة الآتية محققة:

$$\Gamma^{(n)}(x) := \int_0^{+\infty} y^{x-1} \ln^n y e^{-y} dy$$

- من أجل كل $x \in (0, \infty)$ وكل $n \in \mathbb{N}$ لدينا:

$$\Gamma(x+n) = (x+n-1) \cdot (x+n-2) \cdot \dots \cdot (x+1) \cdot x \cdot \Gamma(x)$$

والتي ينتج عنها أن $\Gamma(n+1) = n!$ ، ومن ثم يكون لدينا $0! = \Gamma(1) = 1$ وكذلك $1! = \Gamma(2) = 1$.

- من أجل كل $x \in (0, \infty)$ لدينا:

$$\Gamma(x) \cdot \Gamma(1-x) = \frac{\pi}{\sin \pi x}$$

والتي ينتج عنها أن $\Gamma(\frac{1}{2}) = \sqrt{\pi}$.

- من أجل كل $x \in (0, \infty)$ لدينا:

$$\Gamma(x) = 2 \int_0^{+\infty} t^{2x-1} e^{-t^2} dt$$

ومن النتائج المهمة للعلاقة السابقة النتيجة:

$$\int_0^{+\infty} e^{-t^2} dt = \frac{\Gamma(1/2)}{2} = \frac{\sqrt{\pi}}{2}$$

A-٤-٧ - تعريف (دالة بيتا Beta Function)

لتكن β دالة حقيقية معرفة على المجال $(0, \infty) \times (0, \infty)$ كما يلي:

$$\beta(p, q) := \int_0^1 y^{p-1} (1-y)^{q-1} dy$$

فعندئذ هذه الدالة تُدعى **دالة بيتا**.

يمكن البرهنة على أنه من أجل كل (p, q) من المجال $(0, \infty) \times (0, \infty)$ فإن دالة بيتا تتمتع بالخصائص الآتية:

١- إذا كان $1 < p$ فإنه سيكون لدينا:

$$\beta(p, q) = \frac{q-1}{p+q-1} \beta(p, q-1)$$

٢- إذا كان $1 < q$ فإنه سيكون لدينا:

$$\beta(p, q) = \frac{p-1}{p+q-1} \beta(p-1, q)$$

٣- من أجل كل $m, n \in \mathbb{N}$ يكون لدينا:

$$\beta(n, m) = \frac{(n-1)! (m-1)!}{(n+m-1)!}$$

٤- من أجل كل $(p, q) \in (0, \infty) \times (0, \infty)$ يكون لدينا:

$$\beta(p, q) = \frac{\Gamma(p) \cdot \Gamma(q)}{\Gamma(p+q)}$$

بهذا نختم الملحق **A**

الملحق (B)

توليد جبر الحوادث وبعض المفاهيم من نظرية القياس

سنقدم في هذا الملحق تذكيراً بموضوعات تتعلق بنظرية القياس آخذين في الحسبان الرموز، والمصطلحات، والمفاهيم التي قدّمت في هذا الكتاب، وكذلك نشير إلى أننا لن نخوض في تفصيلات هذه الموضوعات ولن نقدم أمثلة عليها إلا إذا اقتضت الضرورة ذلك حيث يمكن لمن يودّ الاطلاع على أمثلة وتوضيحات إضافية الرجوع إلى المراجع ذات الصلة ومنها [4] و [5] و [8] و [31] و [39] و [42] و [53] و [56] في فهرس المراجع لهذا الكتاب.

من أجل مجموعة Ω ما غير خالية لدينا 2^Ω أسرة (أو صف) كل المجموعات الجزئية من مجموعة Ω ، ومن أجل $\Omega \supseteq A$ تكون المجموعة \bar{A} هي متممة المجموعة A بالنسبة إلى Ω .

B-1 - توليد جبر الحوادث Generating an Algebra of Events

لقد قدّمنا في الفصل الرابع مفهومي جبر الحوادث و σ -جبر لحوادث مع توضيحات واستنتاجات كثيرة كانت موضع اهتمامنا في ذلك الفصل، ولذلك سنقدم فيما يلي مبرهنات نقبلها دون برهان. إن هذه المبرهنات توضح لنا كيفية توليد جبر الحوادث من حادث أو صف حوادث غير خال $\mathcal{S} \subseteq 2^\Omega$ ، وللوصول إلى هذه الغاية سنعرّف بعض الرموز اللازمة لذلك.

لتكن Ω مجموعة نتائج تجربة عشوائية (غير خالية)، ولنأخذ $\mathcal{S} \subseteq 2^\Omega$ صفًا غير خال من الحوادث، ولنضع بالتعريف ما يلي:

$$C(\mathcal{S}) = \mathcal{S} \cup \{ \bar{A} ; A \in \mathcal{S} \}$$

$$D(\mathcal{S}) = \left\{ \bigcap_{k=1}^n A_k ; A_k \in \mathcal{S}, k \in \mathbb{N}_n \right\}$$

$$V(\mathcal{S}) = \left\{ \bigcup_{k=1}^n A_k ; A_k \in \mathcal{S}, k \in \mathbb{N}_n \right\}$$

$$V_d(\mathcal{S}) = \left\{ \bigcup_{k=1}^n A_k ; A_k \in \mathcal{S} \text{ with } A_k \cap A_\ell = \emptyset, k, \ell \in \mathbb{N}_n \right\}$$

B-1-1 - مبرهنة

لتكن Ω مجموعة نتائج تجربة عشوائية (غير خالية)، ولنأخذ $\mathcal{S} \subseteq 2^\Omega$ صفًا غير خال من الحوادث، فعندئذ يمكن توليد جبر \mathcal{A} فوق Ω من خلال إحدى العمليات الآتية:

$$a) \quad \mathcal{A} = V(D(C(\mathcal{S})))$$

$$b) \quad \mathcal{A} = V(C(V(C(\mathcal{S}))))$$

$$c) \quad \mathcal{A} = V_d \left(D \left(C(\mathcal{S}) \right) \right)$$

وحيث يُدعى الصف \mathcal{S} **صفاً مولّداً** للجبر \mathcal{A} (وُيرمز عادةً للجبر المولّد من صف مجموعات \mathcal{S} بـ $\alpha(\mathcal{S})$).

B-١-٢-أمثلة

١- إنَّ الجبر المبتذل يولّد على النحو الآتي:

نأخذ الصف $\mathcal{Z} = \{\Omega\}$ (التجزئة المبتذلة)، فنجد أنَّها تولّد أضعف جبر فوق Ω لأنَّه باستخدام العملية (a) نجد ما يلي:

$$\mathcal{C} := C(\mathcal{Z}) = \mathcal{Z} \cup \{\bar{A} \mid A \in \mathcal{Z}\} = \{\Omega\} \cup \{\emptyset\} = \{\Omega, \emptyset\}$$

$$\mathcal{D} := D(C(\mathcal{Z})) = D(\mathcal{C}) = \left\{ \bigcap_{k=1}^n A_k ; A_k \in \mathcal{C}, k \in \mathbb{N}_n \right\} = \{\Omega, \emptyset\}$$

$$\mathcal{A} = \alpha(\mathcal{Z}) = V(D(C(\mathcal{Z}))) = V(\mathcal{D}) = \left\{ \bigcup_{k=1}^n A_k ; A_k \in \mathcal{D}, k \in \mathbb{N}_n \right\} = \{\Omega, \emptyset\}$$

كما يمكن استخدام بقية العمليات للحصول على النتيجة نفسها.

٢- يمكننا توليد جبر من حادث $\Omega \supseteq A$ على النحو الآتي:

نأخذ $\Omega \supseteq A$ حادثاً، ونضع $\mathcal{S} := \{A\}$ ، فعندئذ يكون لدينا:

$$\mathcal{C} = C(\mathcal{S}) = \mathcal{S} \cup \{\bar{A} ; A \in \mathcal{S}\} = \{A\} \cup \{\bar{A}\} = \{A, \bar{A}\}$$

$$\mathcal{D} = D(C(\mathcal{S})) = D(\mathcal{C}) = \left\{ \bigcap_{k=1}^n A_k ; A_k \in \mathcal{C}, k \in \mathbb{N}_n \right\} = \{A, \bar{A}, \emptyset\}$$

$$\mathcal{A} = \alpha(\mathcal{S}) = V(D(C(\mathcal{S}))) = V(\mathcal{D}) = \left\{ \bigcup_{k=1}^n A_k ; A_k \in \mathcal{D}, k \in \mathbb{N}_n \right\} = \{\emptyset, A, \bar{A}, \Omega\}$$

كما يمكن استخدام بقية العمليات للحصول على النتيجة نفسها.

٣- يمكننا توليد جبر من صف حوادث بسيطة على النحو الآتي:

على سبيل التوضيح والتبسيط سنأخذ المجموعة $\Omega := \{\omega_1, \omega_2, \omega_3\}$ ، ولنأخذ الصف $\mathcal{S} := \{\{\omega_1\}, \{\omega_2\}\}$ ، فعندئذ يكون لدينا الآتي:

$$\mathcal{C} = C(\mathcal{S}) = \mathcal{S} \cup \{\bar{A} ; A \in \mathcal{S}\} = \{\{\omega_1\}, \{\omega_2\}\} \cup \{\{\omega_2, \omega_3\}, \{\omega_1, \omega_3\}\} = \{\{\omega_1\}, \{\omega_2\}, \{\omega_2, \omega_3\}, \{\omega_1, \omega_3\}\}$$

$$\mathcal{D} = D(C(\mathcal{S})) = D(\mathcal{C}) = \left\{ \bigcap_{k=1}^n A_k ; A_k \in \mathcal{C}, k \in \mathbb{N}_n \right\} = \{\{\omega_1\}, \{\omega_2\}, \{\omega_3\}, \{\omega_2, \omega_3\}, \{\omega_1, \omega_3\}, \emptyset\}$$

$$\mathcal{A} = \alpha(\mathcal{S}) = V(D(C(\mathcal{S}))) = V(\mathcal{D}) = \left\{ \bigcup_{k=1}^n A_k ; A_k \in \mathcal{D}, k \in \mathbb{N}_n \right\}$$

$$= \{\emptyset, \{\omega_1\}, \{\omega_2\}, \{\omega_3\}, \{\omega_1, \omega_3\}, \{\omega_2, \omega_3\}, \{\omega_1, \omega_2, \omega_3\} = \Omega\} = 2^\Omega$$

وهو الجبر المولّد من الصف \mathcal{S} ، حيث يلاحظ أنَّه الجبر القوي (أقوى جبر) فوق Ω .

٤- كذلك يمكننا تبين أنَّ الجبر القوي 2^Ω يكون مولّداً من:

- التجزئة $\mathcal{Z} = \{\{\omega_1\}, \{\omega_2\}, \dots, \{\omega_n\}\}$ عندما تكون Ω مجموعة منتهية بقدر تساوي $|\Omega| = n$.

- التجزئة $\mathcal{Z} = \{\{\omega_1\}, \{\omega_2\}, \dots, \{\omega_n\}, \dots\}$ عندما تكون Ω مجموعة غير منتهية ولكنها قابلة للعد على الأكثر.

وقبل ختام هذه الفقرة نورد المبرهنة الآتية التي تعرض إحدى طرائق توليد الجبر فوق Ω أيضاً.

B-١-٣ - مبرهنة

ليكن $\mathcal{S} \supset 2^\Omega$ صفاً غير خالٍ من الحوادث، فعندئذ صف الحوادث الآتي:

$$\mathcal{A} = \bigcap_{i \in I; \mathcal{A}_i \supseteq \mathcal{S}} \mathcal{A}_i ; \mathcal{A}_i \text{ is an algebra on } \Omega \text{ for all } i \in I$$

هو من جديد جبر فوق Ω ، وهو أصغر جبر يحوي الصف \mathcal{S} ، وحينئذ يدعى الصف \mathcal{S} بالصف المولد للجبر \mathcal{A} ، ويرمز له بـ $\alpha(\mathcal{S})$.

نشير هنا إلى أن عملية توليد الـ σ -جبر ليست بالبساطة التي وجدناها لدى توليد الجبر، إذ إن العمليات السابقة لتوليد الجبر لا يمكن سحبها على توليد الـ σ -جبر في الحالة العامة.

تقدم لنا المبرهنة الآتية كيفية توليد σ -جبر من صف حوادث غير خالٍ $\mathcal{S} \supset 2^\Omega$.

B-١-٤ - مبرهنة

ليكن $\mathcal{S} \supset 2^\Omega$ صفاً غير خالٍ من الحوادث، فعندئذ صف الحوادث الآتي:

$$\mathcal{A} = \bigcap_{i \in I; \mathcal{A}_i \supseteq \mathcal{S}} \mathcal{A}_i ; \mathcal{A}_i \text{ is a } \sigma\text{-algebra on } \Omega \text{ for all } i \in I$$

هو من جديد σ -جبر فوق Ω ، وهو أصغر σ -جبر يحوي الصف \mathcal{S} ، وفي هذه الحالة يدعى الصف المولد للـ σ -جبر \mathcal{A} ، ويرمز له بـ $\sigma(\mathcal{S})$.

B-١-٥ - أمثلة

١- لتكن لدينا $\Omega = \{1, 2\}$ ، فعندئذ نجد أن:

أ- صف المجموعات $\mathcal{S}_1 = \{\Omega\} \subset 2^\Omega$ يولد الـ σ -جبر $\mathcal{A}_1 = \{\emptyset, \Omega\}$.

ب- صف المجموعات $\mathcal{S}_2 = \{\{1\}\} \subset 2^\Omega$ يولد الـ σ -جبر $\mathcal{A}_2 = \{\emptyset, \{1\}, \{2\}, \Omega\}$.

ج- صف المجموعات $\mathcal{S}_3 = \{\{2\}\} \subset 2^\Omega$ يولد الـ σ -جبر $\mathcal{A}_3 = \{\emptyset, \{1\}, \{2\}, \Omega\}$.

د- صف المجموعات 2^Ω يولد نفسه، وهو σ -جبر أيضاً حيث لدينا $\mathcal{A}_4 = 2^\Omega = \{\emptyset, \{1\}, \{2\}, \{1, 2\} = \Omega\}$.

ونتيجة لما سبق في هذا المثال نلاحظ أن $\mathcal{A}_1 \supset \mathcal{A}_2 \supset \mathcal{A}_3 \supset \mathcal{A}_4 = 2^\Omega$ ، وهكذا نلاحظ أنه من أجل Ω مثبتة استطعنا الحصول على أسرة σ -جبر بحيث تكون هذه الجبر محتواة بعضها في البعض الآخر. بمعنى أن جبر الحوادث المستخدم يمكن أن يولد من صفوف عديدة غير خالية من الحوادث، وهذا يعني أن جبر الحوادث المستخدم ليس وحيداً في الحالة العامة.

B-١-٦ - الحقل البوريلى Borel-Field

ليكن (M, ρ) فضاءً مترياً Metric Space، ولنأخذ صف المجموعات $\mathcal{S} = \{A \subseteq M ; A \text{ open}\}$ ، فعندئذ الـ σ -جبر المولد بالصف \mathcal{S} (أي $\sigma(\mathcal{S})$) يُسمى الـ σ -جبر للمجموعات البوريلى في M ، وفي الحالة الخاصة عندما يكون $M = \mathbb{R}^n$ مع $n \in \mathbb{N}$ كيفي ولكن مثبت، فإن $\sigma(\mathcal{S})$ يدعى الحقل البوريلى، وذلك لأن \mathbb{R}^n مع دالة المسافة الإقليدية $\rho(x, y) = \|x - y\|$ يشكل حقلاً، علماً أن كل مجموعة $A \in \sigma(\mathcal{S})$ تُسمى مجموعة بوريلى، وقد استخدمنا سابقاً الرمز \mathcal{B} للدلالة على الحقل البوريلى الخاص بـ

\mathbb{R}^n . هذا ويمكن إثبات أن كل مجموعة بوريلية يمكن أن تكتب على شكل اتحاد لعدد غير منته من المجالات المفتوحة لأنه من أجل أية مجموعة مفتوحة A من \mathbb{R}^n ستكون حاوية جميع نقاطها الداخلية، ومن ثم يمكننا أن نكتب الآتي:

$$A = \bigcup_{x \in A; A \supseteq V_\varepsilon(x)} V_\varepsilon(x)$$

علماً أن $V_\varepsilon(x)$ هي مجاورة لـ x بنصف قطر $\varepsilon > 0$ ، وفي الحالة الخاصة عندما $n=1$ يمكننا من أجل $A_{k,n} := \left(\frac{k}{n}, \frac{k+1}{n}\right)$ أن نكتب الآتي:

$$A = \bigcup_{n \in \mathbb{N}, k \in \mathbb{Q}; A_{k,n} \subseteq A} A_{k,n}$$

B-1-7 - مبرهنة

إن أي صف من الصفوف الآتية يُشكّل صفاً مولداً لـ σ -جبر \mathfrak{R} (الـ σ -جبر لكل المجموعات البوريلية في \mathbb{R}):

$$\begin{aligned} \mathfrak{S}_1 &= \{(\alpha, \beta) \subseteq \mathbb{R}; \alpha, \beta \in \mathbb{Q}\} & \& \quad \mathfrak{S}_2 = \{[\alpha, \beta) \subseteq \mathbb{R}; \alpha, \beta \in \mathbb{Q}\} \\ \mathfrak{S}_3 &= \{(\alpha, \beta] \subseteq \mathbb{R}; \alpha, \beta \in \mathbb{Q}\} & \& \quad \mathfrak{S}_4 = \{[\alpha, \beta] \subseteq \mathbb{R}; \alpha, \beta \in \mathbb{Q}\} \\ \mathfrak{S}_5 &= \{(-\infty, \beta] \subseteq \mathbb{R}; \beta \in \mathbb{Q}\} & \& \quad \mathfrak{S}_6 = \{(-\infty, \beta) \subseteq \mathbb{R}; \beta \in \mathbb{Q}\} \\ \mathfrak{S}_7 &= \{[\alpha, +\infty) \subseteq \mathbb{R}; \alpha \in \mathbb{Q}\} & \& \quad \mathfrak{S}_8 = \{(\alpha, +\infty) \subseteq \mathbb{R}; \alpha \in \mathbb{Q}\} \end{aligned}$$

B-2 - الصفوف المطردة Monotone classes

ليكن $2^\Omega \supset \mathfrak{M}$ صفاً غير خالٍ، فعندئذ يُقال إن \mathfrak{M} هو صف مطرد إذا وفقط إذا تحقق ما يلي:

١- من أجل أية متتالية مجموعات $(A_n)_{n \in \mathbb{N}}$ غير متناقصة، وعناصرها من \mathfrak{M} ، فإنه سيكون لدينا $\bigcup_{n=1}^{\infty} A_n \in \mathfrak{M}$ أيضاً.

٢- من أجل أية متتالية مجموعات $(A_n)_{n \in \mathbb{N}}$ غير متزايدة، وعناصرها من \mathfrak{M} ، فإنه سيكون لدينا $\bigcap_{n=1}^{\infty} A_n \in \mathfrak{M}$ أيضاً.

تعرض لنا المبرهنات الآتية بعض خصائص الصفوف المطردة والخصائص المتبادلة بين الجبر والصفوف المطردة.

B-2-1 - مبرهنات

١- إن تقاطع أية أسرة غير خالية من الصفوف المطردة هو من جديد صف مطرد.

٢- إذا كان $2^\Omega \supset \mathfrak{S} \neq \emptyset$ ، فعندئذ الصف الناتج عن تقاطع كل الصفوف المطردة الحاوية على الصف \mathfrak{S} هو من جديد صف مطرد على Ω . أي إن الصف الآتي:

$$\mathfrak{M} = \bigcap_{i \in I; \mathfrak{M}_i \supseteq \mathfrak{S}} \mathfrak{M}_i \quad ; \mathfrak{M}_i \text{ is a monotone system for all } i \in I$$

هو صف مطرد على Ω ، وهو أصغر صف مطرد يحوي \mathfrak{S} ، وفي هذه الحالة يُدعى \mathfrak{S} بالصف المولد للصف المطرد \mathfrak{M} ، ويرمز له بـ $\mu(\mathfrak{S})$.

٣- إذا كان \mathcal{A} جبراً على Ω ، فعندئذ سيكون لدينا ما يلي محققاً: $\mu(\mathcal{A}) = \sigma(\mathcal{A})$ ، علماً أن $\mu(\mathcal{A})$ يرمز إلى الصف المطرد المولد من \mathcal{A} .

٤- إن كل σ -جبر على Ω هو صف مطرد على Ω أيضاً.

٥- إذا كان \mathcal{A} جبراً على Ω ، فعندئذ يكون σ -جبراً فوق Ω إذا وفقط إذا كان \mathcal{A} صفاً مطرداً.

B-٣- التطبيقات القياسية Measurable maps

إنَّ التطبيقات القياسية تُعدّ من المفاهيم المهمة جداً في دراسة نظرية القياس عامة وفي مجال نظرية الاحتمالات خاصة ذلك أنَّ هذا المفهوم يُعدّ الحجر الأساس لمفهوم العناصر العشوائية في نظرية الاحتمالات، ولهذا لا بدّ للقارئ من الفهم الجيد لهذا الجانب.

سنقوم فيما يلي بتقديم بسيط وموجز حول التطبيقات القياسية ومن ثمَّ سنعود لاحقاً (بعد تقديم القياس) إلى تناول الدوال القياسية Measurable Functions التي تُعدّ حالة خاصة من التطبيقات القياسية.

لتكن $\Omega \neq \emptyset$ و $G \neq \emptyset$ مجموعتين كيفيتين، وبفرض أنَّ \mathcal{A} و \mathcal{G} هما σ -جبر فوق Ω و G على الترتيب، ولنأخذ $X : \Omega \rightarrow G$ تطبيقاً مفترضاً، وسنضع بالتعريف ما يلي:

$$X^{-1}(B) := \{\omega \in \Omega ; X(\omega) \in B\} \quad ; B \in \mathcal{G}$$

$$X^{-1}(\mathcal{G}) := \{X^{-1}(B) ; B \in \mathcal{G}\} \subseteq \mathcal{A}$$

عندئذ ينتج لدينا من خواص الصورة العكسية للتطبيقات ما يلي:

$$X^{-1}(\emptyset) = \emptyset$$

$$\overline{X^{-1}(B)} = X^{-1}(\bar{B}) \quad ; B \in \mathcal{G}$$

$$X^{-1}\left(\bigcup_{i \in I} B_i\right) = \bigcup_{i \in I} X^{-1}(B_i) \quad ; B_i \in \mathcal{G}, \forall i \in I$$

$$X^{-1}\left(\bigcap_{i \in I} B_i\right) = \bigcap_{i \in I} X^{-1}(B_i) \quad ; B_i \in \mathcal{G}, \forall i \in I$$

B-٣-١- تعريف التطبيق القياسي:

بفرض أنَّ \mathcal{A} و \mathcal{G} هما σ -جبر فوق Ω و G على الترتيب، وليكن $X : \Omega \rightarrow G$ تطبيقاً معطى، فإذا كان من أجل كل $B \in \mathcal{G}$ لدينا $X^{-1}(B)$ هو عنصر من \mathcal{A} ، فعندئذ يُقال إنَّ التطبيق X قياسي بالنسبة إلى \mathcal{A} و \mathcal{G} .

على سبيل المثال لو أخذنا $\Omega = \{1, 2\}$ مجموعة مُعطاة، ولنأخذ σ -جبر $\mathcal{A} = \{\emptyset, \Omega\}$ (الجبر الضعيف فوق Ω)، فعندئذ بفرض أنَّ X تطبيق حقيقي مُعرَّف على Ω من خلال العلاقة $X(\omega) = 0$ ، فإنَّنا سنجد ما يلي:

$$\{X(\omega) < x\} = \begin{cases} \emptyset & \text{for } x \leq 0 \\ \Omega & \text{for } x > 0 \end{cases}$$

وبما أنَّه لدينا بحسب الفرض $\emptyset, \Omega \in \mathcal{A}$ ، فإنَّ ذلك يعني أنَّ التطبيق X قياسي بالنسبة إلى \mathcal{A} و \mathcal{R} .

B-٣-٢- بعض خصائص التطبيقات القياسية:

١- تركيب تطبيقين قيسين هو من جديد تطبيق قياسي.

٢- إذا كانت A و $B \in \mathcal{G}$ مع $A \cap B = \emptyset$ ، فعندئذ إذا كان X تطبيقاً قيسياً بالنسبة إلى \mathcal{A} و \mathcal{G} فإنَّه سيكون لدينا:

$$X^{-1}(A) \cap X^{-1}(B) = \emptyset \in \mathcal{A}$$

٣- بفرض أنَّ \mathcal{A} هو σ -جبر فوق Ω ، وكذلك لدينا \mathcal{G} هو σ -جبر فوق G ، وبفرض أنَّ X تطبيقاً قيسياً بالنسبة إلى \mathcal{A}

$$\mu \left(\sum_{n=1}^{\infty} A_n \right) = \sum_{n=1}^{\infty} \mu(A_n)$$

فعندئذ يُقال عن الدالة μ إنها قياس على الفضاء المقيس $[\Omega, \mathcal{A}]$.

B-٤-٣ - حالات خاصة:

ليكن μ قياساً على الفضاء المقيس $[\Omega, \mathcal{A}]$ ، فعندئذ:

١- إذا كان لدينا $\mu(\Omega) < +\infty$ ، فعندئذ يُدعى μ قياساً منتهياً Finite Measure.

٢- إذا كان لدينا $\mu(\Omega) = 1$ ، فعندئذ يُدعى μ قياساً احتمالياً.

٣- إذا كان $\mu(\Omega) = +\infty$ ، وأمکننا إيجاد متتالية مجموعات $(Z_n)_{n \in \mathbb{N}}$ عناصرها من \mathcal{A} تشكّل تجزئة للمجموعة Ω ، وبحيث إنه من أجل كل $n \in \mathbb{N}$ لدينا $\mu(Z_n) < +\infty$ ، فعندئذ يُقال إن μ هو قياس من نوع σ -منتهى σ -Finite Measure، وبعض المراجع العربية تذكره باسم قياس منتهى عدود.

B-٤-٤ - خصائص القياس:

ليكن μ قياساً على فضاء مقيس $[\Omega, \mathcal{A}]$ ، فعندئذ:

١- من أجل أية مجموعتين $A, B \in \mathcal{A}$ مع $B \supseteq A$ يكون لدينا $\mu(B) \geq \mu(A)$ ، وهذه الخاصية تعرف باسم خاصية الاطراد Monotony للقياس μ .

٢- من أجل أية مجموعتين $A, B \in \mathcal{A}$ مع $B \supseteq A$ وكذلك $\mu(B) < +\infty$ تكون العلاقة الآتية مُحَقَّقة:

$$\mu(B \setminus A) = \mu(B) - \mu(A)$$

٣- من أجل أية مجموعتين $A, B \in \mathcal{A}$ يكون لدينا:

$$\mu(A \cup B) \leq \mu(A) + \mu(B)$$

وهذه الخاصية يُعبّر عنها بالقول: إنَّ القياس μ نصف جمعي Subadditive.

٤- من أجل أية مجموعات $A_1, A_2, \dots, A_n \in \mathcal{A}$ يكون لدينا:

$$\mu \left(\bigcup_{i=1}^n A_i \right) \leq \sum_{i=1}^n \mu(A_i)$$

وهذه الخاصية يُعبّر عنها بالقول: إنَّ القياس μ نصف جمعي منتهى Finite Subadditive.

٥- من أجل أية متتالية مجموعات $(A_n)_{n \in \mathbb{N}}$ عناصرها من \mathcal{A} يكون لدينا:

$$\mu \left(\bigcup_{n=1}^{\infty} A_n \right) \leq \sum_{n=1}^{\infty} \mu(A_n)$$

وهذه الخاصية يُعبّر عنها بالقول: إنَّ القياس μ نصف جمعي σ -منتهى σ -Finite Subadditive (أو نصف جمعي عدود).

نشير أخيراً إلى ضرورة التمييز بين تعبير القياس الوارد في الفصل الأول والقياس الذي يستخدم في نظرية القياس رغم أنه يُستخدم من أجلها الكلمة Measure نفسها.

B-٤-٥ - تعريف (قياس لوبيغ Lebesgue Measure)

لنأخذ الفضاء المقيس $[R, \mathcal{R}]$ ، وليكن λ دالة مجموعات على معرفة \mathcal{R} كما يلي:

$$\lambda([a, b)) = b - a \quad ; a, b \in R, b > a$$

فعندئذ نجد أن λ تحقق شروط القياس على $[R, \mathcal{R}]$ ، وذلك لأنه:

١- لدينا $\lambda(\emptyset) = \lambda([a, a)) = a - a = 0$ من أجل أي $a \in R$.

٢- من أجل أية متتالية فترات $([a_n, b_n))_{n \in \mathbb{N}}$ عناصرها من \mathcal{R} ومنفصلة متتالية، سيكون لدينا ما يلي محققاً:

$$\lambda\left(\sum_{n=1}^{\infty} [a_n, b_n)\right) = \sum_{n=1}^{\infty} \lambda([a_n, b_n))$$

B-٤-٦ - ملاحظات

١- نشير هنا إلى أنه من أجل قياس لوبيغ يوضع من أجل كل $a, b \in R$ مع $b > a$ بالتعريف ما يلي:

$$\lambda([a, b)) = \lambda((a, b]) = \lambda([a, b]) = b - a$$

٢- إضافة لما سبق فإن λ هو قياس من نوع σ -متن، وذلك لأنه لو أخذ التجزئة $\mathcal{Z} = \{[n, n+1); n \in \mathbb{Z}\}$ (وهي مجموعة جزئية من \mathcal{R}) للمجموعة R ، فإننا نجد ما يلي:

$$a) \quad \lambda([n, n+1)) = (n+1) - n = 1 < +\infty$$

$$b) \quad \lambda(R) = \lambda\left(\sum_{n=-\infty}^{\infty} [n, n+1)\right) = \sum_{n=-\infty}^{\infty} \lambda([n, n+1)) = \sum_{n=-\infty}^{\infty} [(n+1) - n] = \sum_{n=-\infty}^{\infty} 1 = +\infty$$

٣- إن قياس لوبيغ على الفضاء المقيس $[R^n, \mathcal{R}^n]$ الذي يرمز له بـ λ^n ، يعرف بشكل مماثل لما سبق حيث يوضع بالتعريف:

$$\lambda^n\left(\prod_{i=1}^n [a_i, b_i)\right) = \prod_{i=1}^n (b_i - a_i) \quad ; a_i, b_i \in R, b_i > a_i$$

٤- يُبرهن على أن قياس لوبيغ λ^n المعطى سابقاً وحيداً على الفضاء المقيس $[R^n, \mathcal{R}^n]$. إن معنى وحدانية قياس لوبيغ على $[R^n, \mathcal{R}^n]$ سيتضح لنا لاحقاً لدى تقديم مبرهنة رادون-نيكوديم.

B-٤-٧ - الاستمرار من الأدنى والأعلى لقياس Lower and Upper Continuity of a measure

ليكن μ دالة مجموعات على فضاء مقيس $[\Omega, \mathcal{A}]$ ، فعندئذ يُقال:

١- إن الدالة μ **مستمرة من الأدنى** إذا كان من أجل أية متتالية مجموعات $(A_n)_{n \in \mathbb{N}}$ عناصر من \mathcal{A} وغير متناقصة، فإن العلاقة الآتية تكون محققة:

$$\mu\left(\lim_{n \rightarrow \infty} A_n\right) = \mu\left(\bigcup_{n=1}^{\infty} A_n\right) = \lim_{n \rightarrow \infty} \mu(A_n)$$

٢- إن الدالة μ **مستمرة من الأعلى** إذا كان من أجل أية متتالية مجموعات $(A_n)_{n \in \mathbb{N}}$ عناصر من \mathcal{A} وغير متزايدة، فإن العلاقة الآتية تكون محققة:

$$\mu\left(\lim_{n \rightarrow \infty} A_n\right) = \mu\left(\bigcap_{n=1}^{\infty} A_n\right) = \lim_{n \rightarrow \infty} \mu(A_n)$$

المبرهنة الآتية تبين لنا أن القياس مستمر من الأدنى والأعلى.

B-٤-٨ - مبرهنة

ليكن μ قياساً على فضاء مقيس $[\Omega, \mathcal{A}]$. عندئذ يكون μ مستمراً من الأدنى والأعلى بأن واحد (ولذلك يُقال إنَّ القياس μ مستمر).

B-٤-٩ - ملاحظات

١- إذا كان $\mu(\Omega) < +\infty$ فإنه من أجل أي $A \in \mathcal{A}$ تكون العلاقة الآتية مُحَقَّقة:

$$\mu(\bar{A}) = \mu(\Omega \setminus A) = \mu(\Omega) - \mu(A)$$

٢- إذا كانت $\mu_1, \mu_2, \dots, \mu_n$ و $(a_n)_{n \in \mathbb{N}}$ متتالية قياسات منتهية فوق فضاء مقيس $[\Omega, \mathcal{A}]$ ، و متتالية عددية من \mathbb{R}^+ ، فعندئذ تكون دالة المجموعات:

$$\mu := \sum_{n=1}^{\infty} a_n \cdot \mu_n$$

قياساً على $[\Omega, \mathcal{A}]$ أيضاً، وعلاوةً على ذلك:

أ- يكون القياس μ منتهٍ إذا وفقط إذا كان:

$$\sum_{n=1}^{\infty} a_n \cdot \mu_n(\Omega) < +\infty.$$

ب- إذا كانت القياسات $\mu_1, \mu_2, \dots, \mu_n$ هي قياسات احتمالية، فعندئذ يكون μ قياساً احتمالياً إذا وفقط إذا كان:

$$\sum_{n=1}^{\infty} a_n = 1$$

المبرهنة الآتية تعرض لنا الصيغة التي تؤول إليها القياسات المنتهية عندما تكون Ω مجموعة قابلة للعد.

B-٤-١٠ - مبرهنة

لتكن Ω مجموعة قابلة للعد على الأكثر، ولنأخذ $\mathcal{A} = 2^\Omega$ ، وليكن μ قياساً من النوع σ -منتهٍ على $[\Omega, \mathcal{A}]$ ، فعندئذ يكون للقياس μ العرض الآتي:

$$\mu(A) = \sum_{\omega \in \Omega} \mu(\{\omega\}) \cdot \delta_\omega(A) \quad ; \forall A \in \mathcal{A}$$

علماً أنَّ δ_ω يرمز إلى قياس ديراك المركز على النقطة ω .

B-٤-١١ - تعريف (فضاء القياس Measure Space)

ليكن μ قياساً على فضاء مقيس $[\Omega, \mathcal{A}]$ ، فعندئذ تُدعى الثلاثية $[\Omega, \mathcal{A}, \mu]$ فضاء قياس.

في الحالة الخاصة إذا كان μ قياساً احتمالياً، فعندئذ يُقال عن فضاء القياس $[\Omega, \mathcal{A}, \mu]$ إنه فضاء احتمالي.

B-٤-١٢ - تعريف (القياس المولّد من تطبيق قيوس)

ليكن $[\Omega, \mathcal{A}, \mu]$ فضاء قياساً و $[G, \mathcal{G}]$ فضاءً مقيساً، ولنأخذ $X: \Omega \rightarrow G$ تطبيقاً قيوساً بالنسبة إلى \mathcal{A} و \mathcal{G} ، فعندئذ يُسمّى القياس $\eta := \mu \circ X^{-1}$ قياساً مولّداً بالتطبيق X ، ويُرمز عادةً لهذا القياس بـ μ_X ، وهكذا يمكننا من أجل أي $B \in \mathcal{G}$ أن نكتب الآتي:

$$\begin{aligned}\eta(B) &= \mu_X(B) = (\mu \circ X^{-1})(B) = \mu(X^{-1}(B)) \\ &= \mu\{\omega \in \Omega ; X(\omega) \in B\} \triangleq \mu(X \in B)\end{aligned}$$

B-٤-١٣- حالات خاصة

- ١- إذا كان القياس μ منتهياً، فإن القياس μ_X سيكون منتهياً أيضاً.
- ٢- إذا كان القياس μ من النوع $-\sigma$ منته، فإن القياس μ_X سيكون من النوع $-\sigma$ منته أيضاً.
- ٣- إذا كان القياس μ احتمالياً، فإن القياس μ_X سيكون قياساً احتمالياً أيضاً، ومن أجل هذه الحالة الخاصة غالباً يستخدم الرمز P و P_X عوضاً عن μ و μ_X على الترتيب، ومن ثم يمكننا أن نكتب من أجل أي $B \in \mathcal{G}$ الآتي:

$$\begin{aligned}P_X(B) &= P \circ X^{-1}(B) = P(X^{-1}(B)) = \int_{X^{-1}(B)} P(d\omega) = \int \mathbf{I}_{X^{-1}(B)}(\omega) P(d\omega) \\ &= \int \mathbf{I}_B(X(\omega)) P(d\omega) = \int \mathbf{I}_B(x) P_X(dx)\end{aligned}$$

وذلك لأن:

$$P_X(B) = \int_B P_X(dx) = \int P_X(dx) \mathbf{I}_B(x)$$

تبحث المبرهنة الآتية في وجود القياس الناتج عن جداء عدد منته من القياسات.

B-٤-١٤- مبرهنة

لتكن $\mu_1, \mu_2, \dots, \mu_n$ قياسات من النوع $-\sigma$ منته على الفضاءات المقاسة $[\Omega_1, \mathcal{A}_1], [\Omega_2, \mathcal{A}_2], \dots, [\Omega_n, \mathcal{A}_n]$ ، ولنأخذ $\bigotimes_{i=1}^n \mathcal{A}_i$ هو الـ $-\sigma$ جبر فوق $\bigotimes_{i=1}^n \Omega_i$. عندئذ يوجد قياس وحيد μ يرمز له بـ $\mu := \mu_1 \times \mu_2 \times \dots \times \mu_n$ على الفضاء المقاس $\left[\bigotimes_{i=1}^n \Omega_i, \bigotimes_{i=1}^n \mathcal{A}_i \right]$ ، وبحيث إنه من أجل أية مجموعات $A_1 \in \mathcal{A}_1, A_2 \in \mathcal{A}_2, \dots, A_n \in \mathcal{A}_n$ تكون العلاقة الآتية محققة:

$$\mu\left(\bigotimes_{k=1}^n A_k\right) = \prod_{k=1}^n \mu_k(A_k)$$

وهو قياس من النوع $-\sigma$ منته.

بناءً على المبرهنة السابقة يكون قياس لوبيغ λ^n هو قياس ضرب (جداء) على $[\mathbb{R}^n, \mathcal{R}^n]$ ، ومن ثم يمكن كتابته على شكل ضرب لقياس لوبيغ بنفسه n مرة أيضاً. أي إنه يمكننا أن نكتب $\lambda^n = \lambda \times \lambda \times \dots \times \lambda$.

B-٥- الدوال القیوسة Measurable Functions

سنقدم فيما يلي مفهوم الدالة القیوسة التي تُعد حالة خاصة من التطبيق القیوس.

B-٥-١- تعريف (الدالة القیوسة)

لتكن f دالة حقيقية معرفة على Ω ، فعندئذ يقال عن f إنها **دالة قیوسة** (أو **دالة قابلة للقياس**) إذا وفقط إذا كانت قیوسة بالنسبة إلى \mathcal{A} و \mathcal{R} ، وعادة يختصر التعبير إلى القول إن f قیوسة بالنسبة إلى \mathcal{A} دون ذكر \mathcal{R} في هذه الحالة الخاصة (أي إذا كانت f دالة حقيقية).

تقدم المبرهنة الآتية بعض الخصائص للدوال القیوسة.

B-٥-٢-مبرهنة

١- بفرض أن f و g دالتين حقیقتین معرفتین على Ω وقیوستین بالنسبة إلى \mathcal{A} ، فعندئذ:

أ- من أجل أي $a, b \in \mathbb{R}$ مع $a \neq 0$ تكون الدالة $af + b$ قیوسة بالنسبة إلى \mathcal{A} أيضاً.

ب- تكون الدالة $|f|$ قیوسة بالنسبة إلى \mathcal{A} أيضاً.

ج- تكون الدالة $f \pm g$ قیوسة بالنسبة إلى \mathcal{A} أيضاً.

د- تكون الدالة $f \cdot g$ قیوسة بالنسبة إلى \mathcal{A} أيضاً.

٢- بفرض أن $(f_n)_{n \in \mathbb{N}}$ متتالية دوال حقیقیة قیوسة بالنسبة إلى \mathcal{A} ، فعندئذ ستكون الدوال الآتية (في حال وجودها) قیوسة بالنسبة إلى \mathcal{A} أيضاً:

$$f = \inf \{f_n ; n \in \mathbb{N}\} \quad \& \quad f = \sup \{f_n ; n \in \mathbb{N}\} \quad \& \quad f = \overline{\lim}_{n \rightarrow \infty} f_n \quad \& \quad f = \underline{\lim}_{n \rightarrow \infty} f_n \quad \& \quad f = \lim_{n \rightarrow \infty} f_n$$

B-٥-٣-ملاحظة

إن الاختبارات التي قدمت من أجل التحقق من قیوسية التطبيقات تبقى سارية المفعول من أجل الدوال الحقیقیة أيضاً.

B-٥-٤-تعريف (تكامل دالة حقیقیة قیوسة Integral of a Measurable Function)

ليكن $[\Omega, \mathcal{A}, \mu]$ فضاء قیاساً، ولناخذ f دالة حقیقیة معرفة على Ω وقیوسة بالنسبة إلى \mathcal{A} . عندئذ يرمز لتكامل الدالة f بالنسبة إلى القیاس μ بأحد العروض الآتية:

$$E_{\mu} f \quad \text{or} \quad \int f d\mu \quad \text{or} \quad \int f(\omega) \mu(d\omega)$$

ويعرف على النحو الآتي:

١- إذا كانت الدالة f بسيطة أو درجية، أي إن $f = \sum_{i=1}^n a_i \cdot \mathbf{I}_{A_i}$ ، فإن تكامل الدالة f بالنسبة إلى القیاس μ يحسب بالعلاقة الآتية:

$$E_{\mu} f = \sum_{i=1}^n a_i \cdot \mu(A_i)$$

٢- إذا كانت الدالة f غير سالبة، فعندئذ توجد متتالية دوال بسيطة $(f_n)_{n \in \mathbb{N}}$ بحيث يكون $\lim_{n \rightarrow \infty} f_n = f$ ، ومن ثم تكامل f بالنسبة إلى μ يحسب بالعلاقة الآتية:

$$E_{\mu} f = \lim_{n \rightarrow \infty} \int f_n d\mu$$

٣- إذا كانت الدالة f كیفية، فعندئذ يمكننا أن نكتب $f = f^+ - f^-$ ، علماً أن:

$$f^+(\omega) = \max \{f(\omega), 0\} = \begin{cases} 0 & \text{for } f(\omega) < 0 \\ f(\omega) & \text{for } f(\omega) \geq 0 \end{cases}$$

$$f^-(\omega) = -\min \{f(\omega), 0\} = \begin{cases} 0 & \text{for } f(\omega) \geq 0 \\ -f(\omega) & \text{for } f(\omega) < 0 \end{cases}$$

فإذا كان $\int f^- d\mu < +\infty$ أو $\int f^+ d\mu < +\infty$ ، فإن تكامل الدالة f بالنسبة إلى μ يعطى بالعلاقة الآتية:

$$E_\mu f = \int f^+ d\mu - \int f^- d\mu$$

B-5-5-تعريف (قابلية المكاملة لدالة حقيقية Integrability of a Real Function)

لتكن $f: \Omega \rightarrow \overline{\mathbb{R}}$ دالة قيوسية بالنسبة إلى \mathcal{A} ، فإذا كان $\int f d\mu < +\infty$ ، فعندئذ يُقال إن f دالة كمولة (أو قابلة للمكاملة) بالنسبة إلى القياس μ .

في الحقيقة يمكن البرهنة على المقولات (المبرهنات) الآتية:

١- إذا كانت $f: \Omega \rightarrow \overline{\mathbb{R}}$ دالة قيوسية بالنسبة إلى \mathcal{A} ، فعندئذ تكون الدالة f كمولة بالنسبة إلى القياس μ إذا وفقط إذا كانت العلاقة $\int |f| d\mu < +\infty$ محققة.

٢- إذا كانت $f: [a, b] \rightarrow \overline{\mathbb{R}}$ قيوسية بالنسبة إلى $\mathbb{R} \cap [a, b]$ ، وكمولة بحسب مفهوم ريمان، فعندئذ يكون لدينا:

$$E_\lambda f = \int_a^b f(x) \lambda(dx) = \int_a^b f(x) dx$$

٣- بفرض أن $[\Omega, \mathcal{A}, \mu]$ فضاء قياس معطى، و $f: \Omega \rightarrow \overline{\mathbb{R}}$ دالة غير سالبة وقيوسية بالنسبة إلى \mathcal{A} ، وبفرض أن $(A_n)_{n \in \mathbb{N}}$ متتالية مجموعات عناصرها من \mathcal{A} ، ولنضع:

$$A := \sum_{n=1}^{\infty} A_n$$

فعندئذ إذا كانت f كمولة بالنسبة إلى μ فإن العلاقة الآتية ستكون محققة:

$$\int_A f d\mu = \int_{\sum_{n=1}^{\infty} A_n} f d\mu = \sum_{n=1}^{\infty} \int_{A_n} f d\mu$$

B-6-5-نظرية بيو-ليفى Beppo Levi's Theorem

لتكن $(f_n)_{n \in \mathbb{N}}$ متتالية دوال حقيقية غير سالبة، وليست متناقصة على \mathbb{R} ، وقيوسية بالنسبة إلى قياس σ -منته μ على $[\mathbb{R}, \mathbb{R}]$ ، فعندئذ إذا كانت المتتالية $(f_n)_{n \in \mathbb{N}}$ متقاربة من دالة حقيقية f (تقارباً نقطياً على الأقل)، فإن العلاقة الآتية ستكون محققة:

$$\lim_{n \rightarrow \infty} \int f_n d\mu = \int \lim_{n \rightarrow \infty} f_n d\mu = \int f d\mu$$

وتعرف هذه المبرهنة باسم نظرية التقارب المطرّد Monotone Convergence Theorem أيضاً.

B-6-5-نظرية فوبيني Fubini Theorem

ليكن μ_1 و μ_2 قياسين من نوع σ -منته، ولنأخذ $f: \Omega_1 \times \Omega_2 \rightarrow \overline{\mathbb{R}}$ دالة حقيقية وقيوسية بالنسبة إلى $\mathcal{A}_1 \otimes \mathcal{A}_2$ ، فإذا كان التكامل $\int f(\omega_1, \omega_2) \mu_1 \times \mu_2 d(\omega_1, \omega_2)$ موجوداً، فعندئذ سيكون كل من التكاملين الآتين موجوداً أيضاً:

$$\int f(\omega_1, \omega_2) \mu_1(d\omega_1) \quad ; \quad \forall \omega_2 \in \Omega$$

$$\int f(\omega_1, \omega_2) \mu_2(d\omega_2) \quad ; \quad \forall \omega_1 \in \Omega$$

وتكون العلاقة الآتية مُحَقَّقة:

$$\begin{aligned} \int f(\omega_1, \omega_2) \mu_1 \times \mu_2 d(\omega_1, \omega_2) &= \int \left[\int f(\omega_1, \omega_2) \mu_1(d\omega_1) \right] \mu_2(d\omega_2) \\ &= \int \left[\int f(\omega_1, \omega_2) \mu_2(d\omega_2) \right] \mu_1(d\omega_1) \end{aligned}$$

إنَّ هذه النظرية تعود إلى الرياضياتي الإيطالي **فوبيني** (Guido Fubini (1879 – 1943).

B-٥-٧-تعريف (يساوي تقريباً في كل مكان (Equal Almost Every Where

ليكن $[\Omega, \mathcal{A}, \mu]$ فضاءً قياساً، ولنأخذ f و g دالتين حقيقيتين غير سالبتين معرفتين على Ω ، فعندئذ يُقال إنَّ f **تساوي** g تقريباً في كل مكان بالنسبة إلى القياس μ **إذا وفقط إذا** كانت العلاقة الآتية مُحَقَّقة:

$$\mu(\{\omega \in \Omega ; f(\omega) \neq g(\omega)\}) = 0$$

وتكتب هذه العلاقة بأحد الأشكال الآتية:

$$f \sim_{\mu} g \quad \text{or} \quad f =_{\mu} g \quad \text{or} \quad f = g \quad ; \mu - a.e.$$

علماً أنَّ العبارة $f = g \quad ; \mu - a.e.$ (يساوي تقريباً في كل مكان) دارجة الاستخدام في التحليل الرياضي وقليل ما تستخدم في العشوائيات، ولكن إذا كان μ قياساً احتمالياً، فعندئذ يُقال إنَّ $f = g$ **باحتمال يساوي الواحد** أو **باحتمال شبه أكيد**، ويكتب ذلك على النحو الآتي:

$$f = g \quad ; \mu - a.s.$$

وكذلك تجدر الإشارة هنا إلى أنَّ العلاقة \sim السابقة هي في الحقيقة علاقة تكافؤ بين f و g ، ولذلك يُقال في حال $f \sim_{\mu} g$ إنَّ الدالتين f و g متكافئتان وفقاً للقياس μ .

أخيراً نشير إلى أنَّ التكافؤ:

$$f =_{\mu} \varnothing \Leftrightarrow \int f d\mu = 0$$

مُحَقَّق دوماً، علماً أنَّ \varnothing ترمز إلى الدالة الصفرية على Ω .

B-٥-٨-تعريف (الاستمرار المطلق (Absolute Continuation

ليكن μ و η قياسين على فضاء مقيس $[\Omega, \mathcal{A}]$. عندئذ يُقال إنَّ القياس η **مستمر مطلقاً** بالنسبة إلى القياس μ (ويُرمز لذلك بـ $\eta \ll \mu$) **إذا وفقط إذا** كان من أجل أي $A \in \mathcal{A}$ مع $\mu(A) = 0$ فإنه ينتج لدينا $\eta(A) = 0$ أيضاً.

B-٥-٩-نظرية رادون – نيكوديم (Radon–Nikodym Theorem

ليكن μ و η قياسين على فضاء مقيس $[\Omega, \mathcal{A}]$ ، فإذا كان μ من نوع σ – منته، فعندئذ تكون المقولتان الآتيتان متكافئتين:

١ – توجد دالة حقيقية غير سالبة f على Ω منتهية تقريباً في كل مكان بالنسبة إلى μ مع:

$$\eta(A) = \int_A f(\omega) \mu(d\omega) \quad ; \quad \forall A \in \mathcal{A}$$

٢ – القياس η هو قياس σ – منته ومستمر مطلقاً بالنسبة إلى القياس μ .

B-٥-١٠ ملاحظات

١- إن الدالة f المذكورة في نص المبرهنة السابقة تُسمى مشتق رادون - نيكوديم أو الكثافة من القياس η بالنسبة إلى القياس μ ، ويكتب ذلك بالشكل الآتي:

$$\frac{d\eta}{d\mu} = f$$

٢- علاوة على ما سبق فإن الدالة f معينة بشكل وحيد. أي إنه إذا وجدت دالة أخرى غير سالبة g على Ω مع:

$$\eta(A) = \int_A g(\omega) \mu(d\omega) \quad ; \forall A \in \mathcal{F} \Rightarrow \mu(\{\omega \in \Omega ; f(\omega) \neq g(\omega)\}) = 0$$

٣- إن الدالة f الواردة في نص المبرهنة السابقة كمولة بالنسبة إلى القياس μ إذا وفقط إذا كان القياس η منته.

٤- لقد ذكرنا سابقاً لدى عرض مبرهنة الوجدانية لقياس لوبيغ على \mathbb{R}^n أننا سنذكر لاحقاً معنى هذه الوجدانية. في الواقع إن معنى الوجدانية في تلك المبرهنة يعني أنه من أجل أي قياس آخر η معرف على \mathbb{R}^n يجب أن يكون هذا القياس مستمراً مطلقاً بالنسبة إلى قياس لوبيغ λ^n ، ومن ثم وجود دالة غير سالبة f قيوسة وكمولة بالنسبة إلى λ^n من أجلها يكون لدينا ما يلي مُحققاً:

$$\frac{d\eta}{d\lambda^n} = f \Leftrightarrow d\eta = f d\lambda^n \Leftrightarrow \int_A d\eta = \int_A f d\lambda^n \quad ; \forall A \in \mathbb{R}^n$$


بهذا نختم الملحق B

الملحق (C)

جداول إحصائية

وملخص

لتوزيعات احتمالية صغيرة




جدول قيم التوزيع الطبيعي المعياري

Standard Normal Distribution Table

من أجل القيم الموجبة لـ Z

z	0.00	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09
0.0	0.5000	0.5040	0.5080	0.5120	0.5160	0.5199	0.5239	0.5279	0.5319	0.5359
0.1	0.5398	0.5438	0.5478	0.5517	0.5557	0.5596	0.5636	0.5675	0.5714	0.5753
0.2	0.5793	0.5832	0.5871	0.5910	0.5948	0.5987	0.6026	0.6064	0.6103	0.6141
0.3	0.6179	0.6217	0.6255	0.6293	0.6331	0.6368	0.6406	0.6443	0.6480	0.6517
0.4	0.6554	0.6591	0.6628	0.6664	0.6700	0.6736	0.6772	0.6808	0.6844	0.6879
0.5	0.6915	0.6950	0.6985	0.7019	0.7054	0.7088	0.7123	0.7157	0.7190	0.7224
0.6	0.7257	0.7291	0.7324	0.7357	0.7389	0.7422	0.7454	0.7486	0.7517	0.7549
0.7	0.7580	0.7611	0.7642	0.7673	0.7704	0.7734	0.7764	0.7794	0.7823	0.7852
0.8	0.7881	0.7910	0.7939	0.7967	0.7995	0.8023	0.8051	0.8078	0.8106	0.8133
0.9	0.8159	0.8186	0.8212	0.8238	0.8264	0.8289	0.8315	0.8340	0.8365	0.8389
1.0	0.8413	0.8438	0.8461	0.8485	0.8508	0.8531	0.8554	0.8577	0.8599	0.8621
1.1	0.8643	0.8665	0.8686	0.8708	0.8729	0.8749	0.8770	0.8790	0.8810	0.8830
1.2	0.8849	0.8869	0.8888	0.8907	0.8925	0.8944	0.8962	0.8980	0.8997	0.9015
1.3	0.9032	0.9049	0.9066	0.9082	0.9099	0.9115	0.9131	0.9147	0.9162	0.9177
1.4	0.9192	0.9207	0.9222	0.9236	0.9251	0.9265	0.9279	0.9292	0.9306	0.9319
1.5	0.9332	0.9345	0.9357	0.9370	0.9382	0.9394	0.9406	0.9418	0.9429	0.9441
1.6	0.9452	0.9463	0.9474	0.9484	0.9495	0.9505	0.9515	0.9525	0.9535	0.9545
1.7	0.9554	0.9564	0.9573	0.9582	0.9591	0.9599	0.9608	0.9616	0.9625	0.9633
1.8	0.9641	0.9649	0.9656	0.9664	0.9671	0.9678	0.9686	0.9693	0.9699	0.9706
1.9	0.9713	0.9719	0.9726	0.9732	0.9738	0.9744	0.9750	0.9756	0.9761	0.9767
2.0	0.9772	0.9778	0.9783	0.9788	0.9793	0.9798	0.9803	0.9808	0.9812	0.9817
2.1	0.9821	0.9826	0.9830	0.9834	0.9838	0.9842	0.9846	0.9850	0.9854	0.9857
2.2	0.9861	0.9864	0.9868	0.9871	0.9875	0.9878	0.9881	0.9884	0.9887	0.9890
2.3	0.9893	0.9896	0.9898	0.9901	0.9904	0.9906	0.9909	0.9911	0.9913	0.9916
2.4	0.9918	0.9920	0.9922	0.9925	0.9927	0.9929	0.9931	0.9932	0.9934	0.9936
2.5	0.9938	0.9940	0.9941	0.9943	0.9945	0.9946	0.9948	0.9949	0.9951	0.9952
2.6	0.9953	0.9955	0.9956	0.9957	0.9959	0.9960	0.9961	0.9962	0.9963	0.9964
2.7	0.9965	0.9966	0.9967	0.9968	0.9969	0.9970	0.9971	0.9972	0.9973	0.9974
2.8	0.9974	0.9975	0.9976	0.9977	0.9977	0.9978	0.9979	0.9979	0.9980	0.9981
2.9	0.9981	0.9982	0.9982	0.9983	0.9984	0.9984	0.9985	0.9985	0.9986	0.9986
3.0	0.9987	0.9987	0.9987	0.9988	0.9988	0.9989	0.9989	0.9989	0.9990	0.9990
3.1	0.9990	0.9991	0.9991	0.9991	0.9992	0.9992	0.9992	0.9992	0.9993	0.9993
3.2	0.9993	0.9993	0.9994	0.9994	0.9994	0.9994	0.9994	0.9995	0.9995	0.9995
3.3	0.9995	0.9995	0.9995	0.9996	0.9996	0.9996	0.9996	0.9996	0.9996	0.9997
3.4	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9998




تابع جدول قيم التوزيع الطبيعي المعياري

Standard Normal Distribution Table

من أجل القيم السالبة لـ Z

z	0.00	-0.01	-0.02	-0.03	-0.04	-0.05	-0.06	-0.07	-0.08	-0.09
-3.4	0.0003	0.0003	0.0003	0.0003	0.0003	0.0003	0.0003	0.0003	0.0003	0.0002
-3.3	0.0005	0.0005	0.0005	0.0004	0.0004	0.0004	0.0004	0.0004	0.0004	0.0003
-3.2	0.0007	0.0007	0.0006	0.0006	0.0006	0.0006	0.0006	0.0005	0.0005	0.0005
-3.1	0.0010	0.0009	0.0009	0.0009	0.0008	0.0008	0.0008	0.0008	0.0007	0.0007
-3.0	0.0013	0.0013	0.0013	0.0012	0.0012	0.0011	0.0011	0.0011	0.0010	0.0010
-2.9	0.0019	0.0018	0.0018	0.0017	0.0016	0.0016	0.0015	0.0015	0.0014	0.0014
-2.8	0.0026	0.0025	0.0024	0.0023	0.0023	0.0022	0.0021	0.0021	0.0020	0.0019
-2.7	0.0035	0.0034	0.0033	0.0032	0.0031	0.0030	0.0029	0.0028	0.0027	0.0026
-2.6	0.0047	0.0045	0.0044	0.0043	0.0041	0.0040	0.0039	0.0038	0.0037	0.0036
-2.5	0.0062	0.0060	0.0059	0.0057	0.0055	0.0054	0.0052	0.0051	0.0049	0.0048
-2.4	0.0082	0.0080	0.0078	0.0075	0.0073	0.0071	0.0069	0.0068	0.0066	0.0064
-2.3	0.0107	0.0104	0.0102	0.0099	0.0096	0.0094	0.0091	0.0089	0.0087	0.0084
-2.2	0.0139	0.0136	0.0132	0.0129	0.0125	0.0122	0.0119	0.0116	0.0113	0.0110
-2.1	0.0179	0.0174	0.0170	0.0166	0.0162	0.0158	0.0154	0.0150	0.0146	0.0143
-2.0	0.0228	0.0222	0.0217	0.0212	0.0207	0.0202	0.0197	0.0192	0.0188	0.0183
-1.9	0.0287	0.0281	0.0274	0.0268	0.0262	0.0256	0.0250	0.0244	0.0239	0.0233
-1.8	0.0359	0.0351	0.0344	0.0336	0.0329	0.0322	0.0314	0.0307	0.0301	0.0294
-1.7	0.0446	0.0436	0.0427	0.0418	0.0409	0.0401	0.0392	0.0384	0.0375	0.0367
-1.6	0.0548	0.0537	0.0526	0.0516	0.0505	0.0495	0.0485	0.0475	0.0465	0.0455
-1.5	0.0668	0.0655	0.0643	0.0630	0.0618	0.0606	0.0594	0.0582	0.0571	0.0559
-1.4	0.0808	0.0793	0.0778	0.0764	0.0749	0.0735	0.0721	0.0708	0.0694	0.0681
-1.3	0.0968	0.0951	0.0934	0.0918	0.0901	0.0885	0.0869	0.0853	0.0838	0.0823
-1.2	0.1151	0.1131	0.1112	0.1093	0.1075	0.1056	0.1038	0.1020	0.1003	0.0985
-1.1	0.1357	0.1335	0.1314	0.1292	0.1271	0.1251	0.1230	0.1210	0.1190	0.1170
-1.0	0.1587	0.1562	0.1539	0.1515	0.1492	0.1469	0.1446	0.1423	0.1401	0.1379
-0.9	0.1841	0.1814	0.1788	0.1762	0.1736	0.1711	0.1685	0.1660	0.1635	0.1611
-0.8	0.2119	0.2090	0.2061	0.2033	0.2005	0.1977	0.1949	0.1922	0.1894	0.1867
-0.7	0.2420	0.2389	0.2358	0.2327	0.2296	0.2266	0.2236	0.2206	0.2177	0.2148
-0.6	0.2743	0.2709	0.2676	0.2643	0.2611	0.2578	0.2546	0.2514	0.2483	0.2451
-0.5	0.3085	0.3050	0.3015	0.2981	0.2946	0.2912	0.2877	0.2843	0.2810	0.2776
-0.4	0.3446	0.3409	0.3372	0.3336	0.3300	0.3264	0.3228	0.3192	0.3156	0.3121
-0.3	0.3821	0.3783	0.3745	0.3707	0.3669	0.3632	0.3594	0.3557	0.3520	0.3483
-0.2	0.4207	0.4168	0.4129	0.4090	0.4052	0.4013	0.3974	0.3936	0.3897	0.3859
-0.1	0.4602	0.4562	0.4522	0.4483	0.4443	0.4404	0.4364	0.4325	0.4286	0.4247
0.0	0.5000	0.4960	0.4920	0.4880	0.4840	0.4801	0.4761	0.4721	0.4681	0.4641




جدول القيم الحرجة لتوزيع ستودنت

Student Distribution Table

d.f. <i>n</i>	α	0.90	0.95	0.975	0.99	0.995	0.999
1		3.078	6.314	12.706	31.821	63.657	318.313
2		1.886	2.920	4.303	6.965	9.925	22.327
3		1.638	2.353	3.182	4.541	5.841	10.215
4		1.533	2.132	2.776	3.747	4.604	7.173
5		1.476	2.015	2.571	3.365	4.032	5.893
6		1.440	1.943	2.447	3.143	3.707	5.208
7		1.415	1.895	2.365	2.998	3.499	4.782
8		1.397	1.860	2.306	2.896	3.355	4.499
9		1.383	1.833	2.262	2.821	3.250	4.296
10		1.372	1.812	2.228	2.764	3.169	4.143
11		1.363	1.796	2.201	2.718	3.106	4.024
12		1.356	1.782	2.179	2.681	3.055	3.929
13		1.350	1.771	2.160	2.650	3.012	3.852
14		1.345	1.761	2.145	2.624	2.977	3.787
15		1.341	1.753	2.131	2.602	2.947	3.733
16		1.337	1.746	2.120	2.583	2.921	3.686
17		1.333	1.740	2.110	2.567	2.898	3.646
18		1.330	1.734	2.101	2.552	2.878	3.610
19		1.328	1.729	2.093	2.539	2.861	3.579
20		1.325	1.725	2.086	2.528	2.845	3.552
21		1.323	1.721	2.080	2.518	2.831	3.527
22		1.321	1.717	2.074	2.508	2.819	3.505
23		1.319	1.714	2.069	2.500	2.807	3.485
24		1.318	1.711	2.064	2.492	2.797	3.467
25		1.316	1.708	2.060	2.485	2.787	3.450
26		1.315	1.706	2.056	2.479	2.779	3.435
27		1.314	1.703	2.052	2.473	2.771	3.421
28		1.313	1.701	2.048	2.467	2.763	3.408
29		1.311	1.699	2.045	2.462	2.756	3.396
30		1.310	1.697	2.042	2.457	2.750	3.385
31		1.309	1.696	2.040	2.453	2.744	3.375
32		1.309	1.694	2.037	2.449	2.738	3.365
33		1.308	1.692	2.035	2.445	2.733	3.356
34		1.307	1.691	2.032	2.441	2.728	3.348
35		1.306	1.690	2.030	2.438	2.724	3.340
36		1.306	1.688	2.028	2.434	2.719	3.333
37		1.305	1.687	2.026	2.431	2.715	3.326
38		1.304	1.686	2.024	2.429	2.712	3.319
39		1.304	1.685	2.023	2.426	2.708	3.313
40		1.303	1.684	2.021	2.423	2.704	3.307
41		1.303	1.683	2.020	2.421	2.701	3.301
42		1.302	1.682	2.018	2.418	2.698	3.296
43		1.302	1.681	2.017	2.416	2.695	3.291
44		1.301	1.680	2.015	2.414	2.692	3.286
45		1.301	1.679	2.014	2.412	2.690	3.281
46		1.300	1.679	2.013	2.410	2.687	3.277
47		1.300	1.678	2.012	2.408	2.685	3.273
48		1.299	1.677	2.011	2.407	2.682	3.269
49		1.299	1.677	2.010	2.405	2.680	3.265
50		1.299	1.676	2.009	2.403	2.678	3.261

جدول القيم الحرجة لتوزيع ستودنت
Student Distribution Table

d.f. <i>n</i>	α	0.90	0.95	0.975	0.99	0.995	0.999
51		1.298	1.675	2.008	2.402	2.676	3.258
52		1.298	1.675	2.007	2.400	2.674	3.255
53		1.298	1.674	2.006	2.399	2.672	3.251
54		1.297	1.674	2.005	2.397	2.670	3.248
55		1.297	1.673	2.004	2.396	2.668	3.245
56		1.297	1.673	2.003	2.395	2.667	3.242
57		1.297	1.672	2.002	2.394	2.665	3.239
58		1.296	1.672	2.002	2.392	2.663	3.237
59		1.296	1.671	2.001	2.391	2.662	3.234
60		1.296	1.671	2.000	2.390	2.660	3.232
61		1.296	1.670	2.000	2.389	2.659	3.229
62		1.295	1.670	1.999	2.388	2.657	3.227
63		1.295	1.669	1.998	2.387	2.656	3.225
64		1.295	1.669	1.998	2.386	2.655	3.223
65		1.295	1.669	1.997	2.385	2.654	3.220
66		1.295	1.668	1.997	2.384	2.652	3.218
67		1.294	1.668	1.996	2.383	2.651	3.216
68		1.294	1.668	1.995	2.382	2.650	3.214
69		1.294	1.667	1.995	2.382	2.649	3.213
70		1.294	1.667	1.994	2.381	2.648	3.211
71		1.294	1.667	1.994	2.380	2.647	3.209
72		1.293	1.666	1.993	2.379	2.646	3.207
73		1.293	1.666	1.993	2.379	2.645	3.206
74		1.293	1.666	1.993	2.378	2.644	3.204
75		1.293	1.665	1.992	2.377	2.643	3.202
76		1.293	1.665	1.992	2.376	2.642	3.201
77		1.293	1.665	1.991	2.376	2.641	3.199
78		1.292	1.665	1.991	2.375	2.640	3.198
79		1.292	1.664	1.990	2.374	2.640	3.197
80		1.292	1.664	1.990	2.374	2.639	3.195
81		1.292	1.664	1.990	2.373	2.638	3.194
82		1.292	1.664	1.989	2.373	2.637	3.193
83		1.292	1.663	1.989	2.372	2.636	3.191
84		1.292	1.663	1.989	2.372	2.636	3.190
85		1.292	1.663	1.988	2.371	2.635	3.189
86		1.291	1.663	1.988	2.370	2.634	3.188
87		1.291	1.663	1.988	2.370	2.634	3.187
88		1.291	1.662	1.987	2.369	2.633	3.185
89		1.291	1.662	1.987	2.369	2.632	3.184
90		1.291	1.662	1.987	2.368	2.632	3.183
91		1.291	1.662	1.986	2.368	2.631	3.182
92		1.291	1.662	1.986	2.368	2.630	3.181
93		1.291	1.661	1.986	2.367	2.630	3.180
94		1.291	1.661	1.986	2.367	2.629	3.179
95		1.291	1.661	1.985	2.366	2.629	3.178
96		1.290	1.661	1.985	2.366	2.628	3.177
97		1.290	1.661	1.985	2.365	2.627	3.176
98		1.290	1.661	1.984	2.365	2.627	3.175
99		1.290	1.660	1.984	2.365	2.626	3.175
100		1.290	1.660	1.984	2.364	2.626	3.174
∞		1.28	1.64	1.96	2.33	2.58	3.15



جدول القيم الحرجة لتوزيع كاي مربع

Chi Square Distribution Table

d.f. <i>n</i>	α					
	0.90	0.950	0.975	0.990	0.995	0.999
1	2.706	3.841	5.024	6.635	7.879	10.8276
2	4.605	5.991	7.378	9.210	10.597	13.8155
3	6.251	7.815	9.348	11.345	12.833	16.2662
4	7.779	9.488	11.143	13.277	14.860	18.4668
5	9.236	11.070	12.832	15.086	16,750	20.5150
6	10.645	12.592	14.449	16.812	18.548	22.4577
7	12,017	14.067	16.013	18.475	20.278	24.3219
8	13.362	15.507	17.535	20.090	21.955	26.1245
9	14.684	16.919	19.023	21.666	23.589	27.8772
10	15.987	18.307	20.483	23.209	25.188	29.5883
11	17.275	19,675	21.920	24,725	26.757	31.2641
12	18,549	21.026	23.336	26.217	28.300	32.9095
13	19.812	22.362	24.736	27.688	29.819	34.5282
14	21.064	23.685	26.119	29.141	31.319	36.1233
15	22.307	24.996	27.488	30.578	32.801	37.6973
16	23.542	26.296	28.845	32.000	34.267	39.2524
17	24.769	27.587	30.191	33.409	35.718	40.7902
18	25.989	28.869	31.526	34.805	37.156	42.3124
19	27.204	30.144	32.852	36.191	38.582	43.8202
20	28.412	31.410	34.170	37.566	39.997	45.3147
21	29.615	32-671	35.479	38.932	41.401	46.7970
22	30,813	33.924	36.781	40.289	42.796	48.2679
23	32.007	35.172	38.076	41.638	44.181	49.7282
24	33.196	36.4)5	39.364	42.980	45.558	51.1786
25	34.382	37.652	40.646	44.314	46.928	52.6197
26	35.563	38.855	41.923	45.642	48-290	54.0520
27	36.741	40.113	43.194	46.963	49.645	55.4760
28	37.916	41.337	44.461	48.278	50.993	56.8923
29	39.087	42.557	45.722	49.588	52.336	58.3012
30	40.256	43.773	46.979	50.892	53.672	59.7031
35	46.059	49.802	53.203	57.342	60.275	66.6188
40	51.805	55.758	59.342	63.691	66.766	73.4019
45	57.505	61.656	65.410	69.957	73.166	80.0767
50	63,167	67.505	71.420	76.154	79-490	86.6608
60	74.397	79-082	83.298	88.379	91.952	99.6072
70	85.527	90.531	95.023	100.425	104.215	112.3169
80	96.578	101.879	106.629	112.329	116.321	124.8392
90	107.565	113.145	118.136	124.116	128.299	137.2083
100	118.498	124.342	129.561	135.807	140.169	149.4492
120	140.233	146.567	152.211	158.950	163.648	173.6174
140	161.827	168.613	174.648	181.840	186.847	197.4508
200	226.021	233.994	241.058	249.445	255.207	267.5405
500	540.9303	553.1268	563.8515	576.4928	585.2066	603.4460

جدول القيم الحرجة لتوزيع كاي مربع
Chi Square Distribution Table

d.f. <i>n</i>	α					
	0.001	0.005	0.01	0.025	0.05	0.10
1	0.000002	0.00004	0.00016	0.00098	0.00393	0.0158
2	0.002001	0.0100	0.0201	0.0506	0.103	0.2107
3	0.02430	0.0717	0.115	0.216	0.352	0.5844
4	0.09080	0.207	0.297	0.484	0.711	1.0636
5	0.2102	0.412	0.554	0.831	1.145	1.6103
6	0.3811	0.676	0.872	1.237	1.635	2.2041
7	0.5985	0.989	1.239	1.690	2.167	2.8331
8	0.8571	1.344	1.646	2.180	2.733	3.4895
9	1.152	1.735	2.088	2.700	3.325	4.1682
10	1.479	2.156	2.558	3.247	3.940	4.8652
11	1.834	2.603	3.053	3.816	4.575	5.5778
12	2.214	3.074	3.571	4.404	5.226	6.3038
13	2.617	3.565	4.107	5.009	5.892	7.0415
14	3.041	4.075	4.660	5.629	6.571	7.7895
15	3.483	4.601	5.229	6.262	7.261	8.5468
16	3.942	5.142	5.813	6.908	7.962	9.3122
17	4.416	5.697	6.408	7.564	8.672	10.0852
18	4.905	6.265	7.015	8.231	9.390	10.8649
19	5.407	6.844	7.633	8.907	10.117	11.6509
20	5.921	7.434	8.260	9.591	10.851	12.4426
21	6.447	8.034	8.897	10.283	11.591	13.2396
22	6.983	8.643	9.542	10.982	12.338	14.0415
23	7.529	9.260	10.196	11.688	13.091	14.8480
24	8.085	9.886	10.856	12.401	13.848	15.6587
25	8.649	10.520	11.524	13.120	14.611	16.4734
26	9.222	11.160	12.198	13.844	15.379	17.2919
27	9.803	11.808	12.878	14.573	16.151	18.1139
28	10.39	12.461	13.565	15.308	16.928	18.9392
29	10.99	13.121	14.256	16.047	17.708	19.7677
30	11.59	13.787	14.953	16.791	18.493	20.5992
35	14.69	17.192	18.509	20.569	22.465	24.7967
40	17.92	20.707	22.164	24.433	26.509	29.0505
45	21.25	24.311	25.901	28.366	30.612	33.3504
50	24.67	27.991	29.707	32.357	34.764	37.6886
60	31.74	35.535	37.485	40.482	43.188	46.4589
70	39.04	43.275	43.275	48.758	51.739	55.3289
80	46.52	51.172	51.172	57.153	60.391	64.2778
90	54.16	59.196	59.196	65.647	69.126	73.2911
100	61.92	67.328	67.328	74.222	77.929	82.3581
120	77.76	83.852	86.923	91.573	95.705	100.6236
140	93.93	100.655	104.034	109.137	113.659	119.0293
200	143.84	152.241	156.432	162.728	168.279	174.8353
500	407.95	422.303	429.388	439.936	449.147	459.9261

جدول القيم الحرجة لتوزيع فيشر
Fischer's Distribution Table

<i>n</i>	$1 - \alpha$	عدد درجات حرية البسط <i>m</i>								
		10	12	15	20	24	30	60	120	∞
1	0.90	60.2	60.7	61.2	61.7	63.0	62.3	62.8	63.1	63.3
	0.95	242	244	246	248	249	250	252	253	254
	0.975	969	977	985	993	997	1.001	1.010	1.014	1.018
	0.99	6.056	6.106	6.157	6.209	6.235	6.261	6.313	6.339	6.366
	0.995	24.22	24.43	24.63	24.84	24.94	25.04	25.25	25.36	25.46
	0.999	605.6	610.7	615.8	620.9	623.5	626.1	631.3	636.6	634.0
2	0.90	9.39	9.41	9.42	9.44	9.45	9.46	9.47	9.48	9.49
	0.95	19.4	19.4	19.4	19.4	19.5	19.5	19.5	19.5	19.5
	0.975	39.4	39.4	39.4	39.4	39.5	39.5	39.5	39.5	39.5
	0.99	99.4	99.4	99.4	99.4	99.5	99.5	99.5	99.5	99.5
	0.995	199	199	199	199	199	199	199	199	200
	0.999	999.4	999.4	999.4	999.4	999.5	999.5	999.5	999.5	999.5
3	0.90	5.23	5.22	5.20	5.18	5.18	5.17	5.15	5.14	5.13
	0.95	8.79	8.74	8.70	8.66	8.64	8.62	8.57	8.55	8.53
	0.975	14.4	14.3	14.3	14.2	14.1	14.1	14.0	13.9	13.9
	0.99	27.2	27.1	26.9	26.7	26.6	26.5	26.3	26.2	26.1
	0.995	43.7	43.4	43.1	42.8	42.6	42.5	42.1	42.0	41.8
	0.999	129.2	128.3	127.4	126.4	125.9	125.4	124.5	124.0	123.5
4	0.90	3.92	3.90	3.87	3.84	3.83	3.82	3.79	3.78	3.76
	0.95	5.96	5.91	5.86	5.80	5.77	5.75	5.69	5.66	5.63
	0.975	8.84	8.73	8.66	8.56	8.51	8.46	8.36	8.31	8.26
	0.99	14.5	14.4	14.2	14.0	13.9	13.8	13.7	13.6	13.5
	0.995	21.0	20.7	20.4	20.2	20.0	19.9	19.6	19.5	19.3
	0.999	48.1	47.4	46.8	46.1	45.8	45.4	44.7	44.4	44.1
5	0.90	3.30	3.27	3.24	3.21	3.19	3.17	3.14	3.12	3.11
	0.95	4.74	4.68	4.62	4.56	4.53	4.50	4.43	4.40	4.37
	0.975	6.62	6.52	6.43	6.33	6.28	6.23	6.12	6.07	6.02
	0.99	10.1	9.89	9.72	9.55	9.47	9.38	9.20	9.11	9.02
	0.995	13.6	13.4	13.1	12.9	12.8	12.7	12.4	12.3	12.1
	0.999	26.9	26.4	25.9	25.4	25.1	24.9	24.3	24.1	23.8
6	0.90	2.94	2.90	2.87	2.84	2.82	2.80	2.76	2.74	2.72
	0.95	4.06	4.00	3.94	3.87	3.84	3.81	3.74	3.70	3.67
	0.975	5.46	5.37	5.27	5.17	5.12	5.07	4.96	4.90	4.85
	0.99	7.87	7.72	7.56	7.40	7.31	7.23	7.06	6.97	6.88
	0.995	10.2	10.0	9.81	9.59	9.47	9.36	9.12	9.00	8.88
	0.999	18.4	18.0	17.6	17.1	16.9	16.7	16.2	16.0	15.7

جدول القيم الحرجة لتوزيع فيشر
Fischer's Distribution Table

<i>n</i>	$1 - \alpha$	عدد درجات حرية البسط <i>m</i>								
		1	2	3	4	5	6	7	8	9
1	0.90	39.9	49.5	53.6	55.8	57.2	58.2	58.9	59.4	59.9
	0.95	161	200	216	225	230	234	237	239	241
	0.975	648	800	864	900	922	937	948	957	963
	0.99	4.052	5.000	5.403	5.625	5.764	5.859	5.928	5.981	6.022
	0.995	16.21	20.00	21.62	22.50	23.06	23.44	23.72	23.93	24.09
	0.999	405.3	500.0	540.4	562.5	576.4	585.9	592.9	598.1	602.3
2	0.90	8.53	9.00	9.16	9.24	9.29	9.33	9.35	9.37	9.38
	0.93	18.5	19.0	19.2	19.2	19.3	19.3	19.4	19.4	19.4
	0.975	38.5	39.0	39.2	39.2	39.3	39.3	39.4	39.4	39.4
	0.99	98.5	99.0	99.2	99.2	99.3	99.3	99.4	99.4	99.4
	0.995	199	199	199	199	199	199	199	199	199
	0.999	998.5	999.0	999.2	999.2	999.3	999.3	999.4	999.4	999.4
3	0.90	5.54	5.46	5.39	5.34	3.31	5.28	5.27	5.25	5.24
	0.95	10.1	9.55	9.28	9.12	9.01	8.94	8.89	8.85	8.81
	0.975	17.4	16.0	15.4	15.1	14.9	14.7	14.6	14.5	14.5
	0.99	34.1	30.8	29.5	28.7	28.2	27.9	27.7	27.5	27.3
	0.995	55.6	49.8	47.5	46.2	45.4	44.8	44.4	44.1	43.9
	0.999	167.0	148.5	141.1	137.1	134.6	132.8	131.6	130.6	129.9
4	0.90	4.54	4.32	4.19	4.11	4.05	4.01	3.98	3.95	3.94
	0.95	7.71	6.94	6.59	6.39	6.26	6.16	6.09	6.04	6.00
	0.975	12.2	10.6	9.98	9.60	9.36	9.20	9.07	8.98	8.90
	0.99	21.2	18.0	16.7	16.0	15.5	15.2	15.0	14.8	14.7
	0.995	31.3	26.3	24.3	23.2	22.5	22.0	21.6	21.4	21.1
	0.999	74.1	61.2	56.2	53.4	51.7	50.5	49.7	49.0	48.5
5	0.90	4.06	3.78	3.62	3.52	3.45	3.40	3.37	3.34	3.32
	0.95	6.61	5.79	5.41	5.19	5.05	4.95	4.88	4.82	4.77
	0.975	10.0	8.43	7.76	7.39	7.15	6.98	6.85	6.76	6.68
	0.99	16.3	13.3	12.1	11.4	11.0	10.7	10.5	10.3	10.2
	0.995	22.8	18.3	16.5	15.6	14.9	14.5	14.2	14.0	13.8
	0.999	47.2	37.1	33.2	31.1	29.8	28.8	28.2	27.6	27.2
6	0.90	3.78	3.46	3.29	3.18	3.11	3.05	3.01	2.98	2.96
	0.95	5.99	5.14	4.76	4.53	4.39	4.28	4.21	4.15	4.10
	0.975	8.81	7.26	6.60	6.23	5.99	5.82	5.70	5.60	5.52
	0.99	13.7	10.9	9.78	9.15	8.75	8.47	8.26	8.10	7.98
	0.995	18.6	14.5	12.9	12.0	11.5	11.1	10.8	10.6	10.4
	0.999	35.5	27.0	23.7	21.9	20.8	20.0	19.5	19.0	18.7

جدول القيم الحرجة لتوزيع فيشر
Fischer's Distribution Table

n	1 - α	عدد درجات حرية البسط m								
		10	12	15	20	24	30	60	120	∞
7	0.90	2.70	2.67	2.63	2.59	2.58	2.56	2.51	2.49	2.47
	0.95	3.64	3.57	3.51	3.44	3.41	3.38	3.30	3.27	3.23
	0.975	4.76	4.67	4.57	4.47	4.42	4.36	4.25	4.20	4.14
	0.99	6.62	6.47	6.31	6.16	6.07	5.99	5.82	5.74	5.65
	0.995	8.38	8.18	7.97	7.75	7.65	7.53	7.31	7.19	7.08
	0.999	14.1	13.7	13.3	12.9	12.7	12.5	12.1	11.9	11.7
8	0.90	2.54	2.50	2.46	2.42	2.40	2.38	2.34	2.32	2.29
	0.95	3.35	3.28	3.22	3.15	3.12	3.08	3.01	2.97	2.93
	0.975	4.30	4.20	4.10	4.00	3.95	3.89	3.78	3.73	3.67
	0.99	5.81	5.67	5.52	5.36	5.28	5.20	5.03	4.95	4.86
	0.995	7.21	7.01	6.81	6.61	6.50	6.40	6.18	6.06	5.95
	0.999	11.5	11.2	10.8	10.5	10.3	10.1	9.73	9.53	9.33
9	0.90	2.42	2.38	2.34	2.30	2.28	2.25	2.21	2.18	2.16
	0.95	3.14	3.07	3.01	2.94	2.90	2.86	2.79	2.75	2.71
	0.975	3.96	3.87	3.77	3.67	3.61	3.56	3.43	3.39	3.33
	0.99	5.26	5.11	4.96	4.81	4.73	4.65	4.48	4.40	4.31
	0.995	6.42	6.23	6.03	5.83	5.73	5.62	5.41	5.30	5.19
	0.999	9.89	9.57	9.24	8.90	8.72	8.55	8.19	8.00	7.81
10	0.90	2.32	2.28	2.24	2.20	2.18	2.16	2.11	2.08	2.06
	0.95	2.98	2.91	2.84	2.77	2.74	2.70	2.62	2.58	2.54
	0.975	3.72	3.62	3.52	3.42	3.37	3.31	3.20	3.14	3.08
	0.99	4.85	4.71	4.56	4.41	4.33	4.25	4.08	4.00	3.91
	0.995	5.85	5.66	5.47	5.27	5.17	5.07	4.86	4.75	4.64
	0.999	8.75	8.45	8.13	7.80	7.64	7.47	7.12	6.94	6.76
12	0.90	2.19	2.15	2.10	2.06	2.04	2.01	1.96	1.93	1.90
	0.95	2.75	2.69	2.62	2.54	2.51	2.47	2.38	2.34	2.30
	0.975	3.37	3.28	3.18	3.07	3.02	2.96	2.85	2.79	2.72
	0.99	4.30	4.16	4.01	3.86	3.78	3.70	3.54	3.45	3.36
	0.995	5.09	4.91	4.72	4.53	4.43	4.33	4.12	4.01	3.90
	0.999	7.29	7.00	6.71	6.40	6.25	6.09	5.76	5.59	5.42
15	0.90	2.06	2.02	1.97	1.92	1.90	1.87	1.82	1.79	1.76
	0.95	2.54	2.48	2.40	2.33	2.29	2.25	2.16	2.11	2.07
	0.975	3.06	2.96	2.86	2.76	2.70	2.64	2.52	2.46	2.40
	0.99	3.80	3.67	3.52	3.37	3.29	3.21	3.05	2.96	2.87
	0.995	4.42	4.25	4.07	3.88	3.79	3.69	3.48	3.37	3.26
	0.999	6.08	5.81	5.54	5.25	5.10	4.95	4.64	4.48	4.31

جدول القيم الحرجة لتوزيع فيشر
Fischer's Distribution Table

<i>n</i>	$1 - \alpha$	عدد درجات حرية البسط <i>m</i>								
		1	2	3	4	5	6	7	8	9
7	0.90	3.59	3.26	3.07	2.96	2.88	2.83	2.78	2.75	2.72
	0.95	5.59	4.74	4.35	4.12	3.97	3.87	3.79	3.73	3.68
	0.975	8.07	6.54	5.89	5.52	5.29	5.12	4.99	4.90	4.82
	0.99	12.2	9.55	8.45	7.85	7.46	7.19	6.99	6.84	6.72
	0.995	16.2	12.4	10.9	10.1	9.52	9.16	8.89	8.68	8.51
	0.999	29.2	21.7	18.8	17.2	16.2	15.5	15.0	14.6	14.3
8	0.90	3.46	3.11	2.92	2.81	2.73	2.67	2.62	2.59	2.56
	0.95	5.32	4.46	4.07	3.84	3.69	3.58	3.50	3.44	3.39
	0.975	7.57	6.06	5.42	5.05	4.82	4.65	4.53	4.43	4.36
	0.99	11.3	8.65	7.59	7.01	6.63	6.37	6.18	6.03	5.91
	0.995	14.7	11.0	9.60	8.81	8.30	7.95	7.69	7.50	7.34
	0.999	25.4	18.5	15.8	14.4	13.5	12.9	12.4	12.0	11.8
9	0.90	3.36	3.01	2.81	2.69	2.61	2.55	2.51	2.47	2.44
	0.95	5.12	4.26	3.86	3.63	3.48	3.37	3.29	3.23	3.18
	0.975	7.21	5.71	5.08	4.72	4.48	4.32	4.20	4.10	4.03
	0.99	10.6	8.02	6.99	6.42	6.06	5.80	5.61	5.47	5.35
	0.995	13.6	10.1	8.72	7.96	7.47	7.13	6.88	6.69	6.54
	0.999	22.9	16.4	13.9	12.6	11.7	11.1	10.7	10.4	10.1
10	0.90	3.28	2.92	2.73	2.61	2.52	2.46	2.41	2.38	2.35
	0.95	4.96	4.10	3.71	3.48	3.33	3.22	3.14	3.07	3.02
	0.975	6.94	5.46	4.83	4.47	4.24	4.07	3.95	3.85	3.78
	0.99	10.0	7.56	6.55	5.99	5.64	5.39	5.20	5.06	4.94
	0.995	12.8	9.43	8.08	7.34	6.87	6.54	6.30	6.12	5.97
	0.999	21.0	14.9	12.6	11.3	10.5	9.92	9.52	9.20	8.96
12	0.90	3.18	2.81	2.61	2.48	2.39	2.33	2.28	2.24	2.21
	0.95	4.75	3.89	3.49	3.26	3.11	3.00	2.91	2.85	2.80
	0.975	6.55	5.10	4.47	4.12	3.89	3.73	3.61	3.51	3.44
	0.99	9.33	6.93	5.95	5.41	5.06	4.82	4.64	4.50	4.39
	0.995	11.8	8.51	7.23	6.52	6.07	5.76	5.52	5.35	5.20
	0.999	18.6	13.0	10.8	9.63	8.89	8.38	8.00	7.71	7.48
15	0.90	3.07	2.70	2.49	2.36	2.27	2.21	2.16	2.12	2.09
	0.95	4.54	3.68	3.29	3.06	2.90	2.79	2.71	2.64	2.59
	0.975	6.20	4.76	4.15	3.80	3.58	3.41	3.29	3.20	3.12
	0.99	8.68	6.36	5.42	4.89	4.56	4.32	4.14	4.00	3.89
	0.995	10.8	7.70	6.48	5.80	5.37	5.07	4.85	4.67	4.54
	0.999	16.6	11.3	9.34	8.25	7.57	7.09	6.74	6.47	6.26

جدول القيم الحرجة لتوزيع فيشر

Fischer's Distribution Table

<i>n</i>	$1 - \alpha$	عدد درجات حرية البسط <i>m</i>								
		10	12	15	20	24	30	60	120	∞
20	0.90	1.94	1.89	1.84	1.79	1.77	1.74	1.68	1.64	1.61
	0.95	2.35	2.28	2.20	2.12	2.08	2.04	1.95	1.90	1.84
	0.975	2.77	2.68	2.57	2.46	2.41	2.35	2.22	2.16	2.09
	0.99	3.37	3.23	3.09	2.94	2.86	2.78	2.61	2.52	2.42
	0.995	3.85	3.68	3.50	3.32	3.22	3.12	2.92	2.81	2.69
	0.999	5.08	4.82	4.56	4.29	4.15	4.00	3.70	3.54	3.38
24	0.90	1.88	1.83	1.78	1.73	1.70	1.67	1.61	1.57	1.53
	0.95	2.25	2.18	2.11	2.03	1.98	1.94	1.84	1.79	1.73
	0.975	2.64	2.54	2.44	2.33	2.27	2.21	2.08	2.01	1.94
	0.99	3.17	3.03	2.89	2.74	2.66	2.58	2.40	2.31	2.21
	0.995	3.59	3.42	3.25	3.06	2.97	2.87	2.66	2.55	2.43
	0.999	4.64	4.39	4.14	3.87	3.74	3.59	3.29	3.14	2.97
30	0.90	1.82	1.77	1.72	1.67	1.64	1.61	1.54	1.30	1.46
	0.95	2.16	2.09	2.01	1.93	1.89	1.84	1.74	1.68	1.62
	0.975	2.51	2.41	2.31	2.20	2.14	2.07	1.94	1.87	1.79
	0.99	2.98	2.84	2.70	2.55	2.47	2.39	2.21	2.11	2.01
	0.995	3.34	3.18	3.01	2.82	2.73	2.63	2.42	2.30	2.18
	0.999	4.24	4.00	3.75	3.49	3.36	3.22	2.92	2.76	2.59
60	0.90	1.71	1.66	1.60	1.54	1.51	1.48	1.40	1.35	1.29
	0.95	1.99	1.92	1.84	1.75	1.70	1.65	1.53	1.47	1.39
	0.975	2.27	2.17	2.06	1.94	1.88	1.82	1.67	1.58	1.48
	0.99	2.63	2.50	2.35	2.20	2.12	2.03	1.84	1.73	1.60
	0.995	2.90	2.74	2.57	2.39	2.29	2.19	1.96	1.83	1.69
	0.999	3.54	3.32	3.08	2.83	2.69	2.55	2.25	2.08	1.89
120	0.90	1.65	1.60	1.55	1.48	1.45	1.41	1.32	1.26	1.19
	0.95	1.91	1.83	1.75	1.66	1.61	1.55	1.43	1.35	1.25
	0.975	2.16	2.05	1.93	1.82	1.76	1.69	1.53	1.43	1.31
	0.99	2.47	2.34	2.19	2.03	1.95	1.86	1.66	1.53	1.38
	0.995	2.71	2.54	2.37	2.19	2.09	1.98	1.75	1.61	1.43
	0.999	3.24	3.02	2.78	2.53	2.40	1.26	1.95	1.77	1.54
∞	0.90	1.60	1.55	1.49	1.42	1.38	1.34	1.24	1.17	1.00
	0.95	1.83	1.75	1.67	1.57	1.52	1.46	1.32	1.22	1.00
	0.975	2.05	1.94	1.83	1.71	1.64	1.57	1.39	1.27	1.00
	0.99	2.32	2.18	2.04	1.88	1.79	1.70	1.47	1.32	1.00
	0.995	2.52	2.36	2.19	2.00	1.90	1.79	1.53	1.36	1.00
	0.999	2.96	2.74	2.51	2.27	2.13	1.99	1.66	1.45	1.00

جدول القيم الحرجة لتوزيع فيشر
Fischer's Distribution Table

<i>n</i>	$1 - \alpha$	عدد درجات حرية البسط <i>m</i>								
		1	2	3	4	5	6	7	8	9
20	0.90	2.97	2.59	2.38	2.25	2.16	2.09	2.04	2.00	1.95
	0.95	4.35	3.49	3.10	2.87	2.71	2.60	2.51	2.45	2.39
	0.975	5.87	4.46	3.86	3.51	3.29	3.13	3.01	2.91	2.84
	0.99	8.10	5.85	4.94	4.43	4.10	3.87	3.70	3.56	3.46
	0.995	9.94	6.99	5.82	5.17	4.76	4.47	4.26	4.09	3.96
	0.999	14.8	9.95	8.10	7.10	6.46	6.02	5.69	5.44	5.24
24	0.90	2.93	2.54	2.33	2.19	2.10	2.04	1.98	1.94	1.91
	0.95	4.26	3.40	3.01	2.78	2.62	2.51	2.42	2.36	2.30
	0.975	5.72	4.32	3.72	3.38	3.15	2.99	2.87	2.78	2.70
	0.99	7.82	5.61	4.72	4.22	3.90	3.67	3.50	3.36	3.26
	0.995	9.55	6.66	5.52	4.89	4.49	4.20	3.99	3.83	3.69
	0.999	14.0	10.6	8.52	7.39	6.68	6.18	5.82	5.54	5.31
30	0.90	2.88	2.49	2.28	2.14	2.05	1.98	1.93	1.88	1.85
	0.95	4.17	3.32	2.92	2.69	2.53	2.42	2.33	2.27	2.21
	0.975	5.57	4.18	3.59	3.25	3.03	2.87	2.75	2.65	2.57
	0.99	7.56	5.39	4.51	4.02	3.70	3.47	3.30	3.17	3.07
	0.995	9.18	6.35	5.24	4.62	4.23	3.95	3.74	3.58	3.45
	0.999	13.3	8.77	7.05	6.12	5.53	5.12	4.82	4.58	4.39
60	0.90	2.79	2.39	2.18	2.04	1.95	1.87	1.82	1.77	1.74
	0.95	4.00	3.15	2.76	2.53	2.37	2.25	2.17	2.10	2.04
	0.975	5.29	3.93	3.34	3.01	2.79	2.63	2.51	2.41	2.33
	0.99	7.08	4.98	4.13	3.65	3.34	3.12	2.95	2.82	2.72
	0.995	8.49	5.80	4.73	4.14	3.76	3.49	3.29	3.13	3.01
	0.999	12.0	8.65	6.81	5.82	4.76	4.37	4.09	3.87	3.69
120	0.90	2.75	2.35	2.13	1.99	1.90	1.82	1.77	1.72	1.68
	0.95	3.92	3.07	2.68	2.45	2.29	2.18	2.09	2.02	1.96
	0.975	5.15	3.80	3.23	2.89	2.67	2.52	2.39	2.30	2.22
	0.99	6.85	4.79	3.95	3.48	3.17	2.96	2.79	2.66	2.56
	0.995	8.18	5.54	4.50	3.92	3.55	3.28	3.09	2.93	2.81
	0.999	11.4	7.32	5.79	4.95	4.42	4.04	3.77	3.55	3.38
∞	0.90	2.71	2.30	2.08	1.94	1.85	1.77	1.72	1.67	1.63
	0.95	3.84	3.00	2.60	2.37	2.21	2.10	2.01	1.94	1.88
	0.975	5.02	3.69	3.12	2.79	2.57	2.41	2.29	2.19	2.11
	0.99	6.63	4.61	3.78	3.32	3.02	2.80	2.64	2.51	2.41
	0.995	7.88	5.30	4.28	3.72	3.35	3.09	2.90	2.74	2.62
	0.999	10.8	6.91	5.42	4.62	4.10	3.74	3.47	3.27	3.30

تابع جدول قيم دالة التوزيع الحداني

Binomial Distribution

∑_{ℓ=0}^k b(ℓ;n,p) = ∑_{ℓ=0}^k \binom{n}{ℓ} \cdot p^ℓ \cdot (1-p)^{n-ℓ}

n	k	p									
		0.10	0.20	0.25	0.30	0.40	0.50	0.60	0.70	0.80	0.90
8	0	0.4305	0.1678	0.1001	0.0576	0.0168	0.0039	0.0007	0.0001	0.0000	
	1	0.8131	0.5033	0.3671	0.2553	0.1064	0.0352	0.0085	0.0013	0.0001	
	2	0.9619	0.7969	0.6785	0.5518	0.3154	0.1445	0.0498	0.0113	0.0012	0.0000
	3	0.9950	0.9437	0.8862	0.8059	0.5941	0.3633	0.1737	0.0580	0.0104	0.0004
	4	0.9996	0.9896	0.9727	0.9420	0.8263	0.6367	0.4059	0.1941	0.0563	0.0050
	5	1.0000	0.9988	0.9958	0.9887	0.9502	0.8555	0.6846	0.4482	0.2031	0.0381
	6		0.9999	0.9996	0.9987	0.9915	0.9648	0.8936	0.7447	0.4967	0.1869
	7		1.0000	1.0000	0.9999	0.9993	0.9961	0.9832	0.9424	0.8322	0.5695
	8				1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
9	0	0.3874	0.1342	0.0751	0.0404	0.0101	0.0020	0.0003	0.0000		
	1	0.7748	0.4362	0.3003	0.1960	0.0705	0.0195	0.0038	0.0004	0.0000	
	2	0.9470	0.7382	0.6007	0.4628	0.2318	0.0898	0.0250	0.0043	0.0003	0.0000
	3	0.9917	0.9144	0.8343	0.7297	0.4826	0.2539	0.0994	0.0253	0.0031	0.0001
	4	0.9991	0.9804	0.9511	0.9012	0.7334	0.5000	0.2666	0.0988	0.0196	0.0009
	5	0.9999	0.9969	0.9900	0.9747	0.9006	0.7461	0.5174	0.2703	0.0856	0.0083
	6	1.0000	0.9997	0.9987	0.9957	0.9750	0.9102	0.7682	0.5372	0.2618	0.0530
	7		1.0000	0.9999	0.9996	0.9962	0.9805	0.9295	0.8040	0.5638	0.2252
	8			1.0000	1.0000	0.9997	0.9980	0.9899	0.9596	0.8658	0.6126
	9					1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
10	0	0.3487	0.1074	0.0563	0.0282	0.0060	0.0010	0.0001	0.0000		
	1	0.7361	0.3758	0.2440	0.1493	0.0464	0.0107	0.0017	0.0001	0.0000	
	2	0.9298	0.6778	0.5256	0.3828	0.1673	0.0547	0.0123	0.0016	0.0001	
	3	0.9872	0.8791	0.7759	0.6496	0.3823	0.1719	0.0548	0.0106	0.0009	0.0000
	4	0.9984	0.9672	0.9219	0.8497	0.6331	0.3770	0.1662	0.0473	0.0064	0.0001
	5	0.9999	0.9936	0.9803	0.9527	0.8338	0.6230	0.3669	0.1503	0.0328	0.0016
	6	1.0000	0.9991	0.9965	0.9894	0.9452	0.8281	0.6177	0.3504	0.1209	0.0128
	7		0.9999	0.9996	0.9984	0.9877	0.9453	0.8327	0.6172	0.3222	0.0702
	8		1.0000	1.0000	0.9999	0.9983	0.9893	0.9536	0.8507	0.6242	0.2639
	9				1.0000	0.9999	0.9990	0.9940	0.9718	0.8926	0.6513
	10					1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
11	0	0.3138	0.0859	0.0422	0.0198	0.0036	0.0005	0.0000			
	1	0.6974	0.3221	0.1971	0.1130	0.0302	0.0059	0.0007	0.0000		
	2	0.9104	0.6174	0.4552	0.3127	0.1189	0.0327	0.0059	0.0006	0.0000	
	3	0.9815	0.8389	0.7133	0.5696	0.2963	0.1133	0.0293	0.0043	0.0002	
	4	0.9972	0.9496	0.8854	0.7897	0.5328	0.2744	0.0994	0.0216	0.0020	0.0000
	5	0.9997	0.9883	0.9657	0.9218	0.7535	0.5000	0.2465	0.0782	0.0117	0.0003
	6	1.0000	0.9980	0.9924	0.9784	0.9006	0.7256	0.4672	0.2103	0.0504	0.0028
	7		0.9998	0.9988	0.9957	0.9707	0.8867	0.7037	0.4304	0.1611	0.0185
	8		1.0000	0.9999	0.9994	0.9941	0.9673	0.8811	0.6873	0.3826	0.0896
	9			1.0000	1.0000	0.9993	0.9941	0.9698	0.8870	0.6779	0.3026
	10					1.0000	0.9995	0.9964	0.9802	0.9141	0.6862
	11						1.0000	1.0000	1.0000	1.0000	1.0000

تابع جدول قيم دالة التوزيع الحداني

Binomial Distribution

$$\sum_{\ell=0}^k \mathbf{b}(\ell;n,p) = \sum_{\ell=0}^k \binom{n}{\ell} \cdot p^{\ell} \cdot (1-p)^{n-\ell}$$

n	k	p									
		0.10	0.20	0.25	0.30	0.40	0.50	0.60	0.70	0.80	0.90
12	0	0.2824	0.0687	0.0317	0.0138	0.0022	0.0002	0.0000			
	1	0.6590	0.2749	0.1584	0.0850	0.0196	0.0032	0.0003	0.0000		
	2	0.8891	0.5583	0.3907	0.2528	0.0834	0.0193	0.0028	0.0002	0.0000	
	3	0.9744	0.7946	0.6488	0.4925	0.2253	0.0730	0.0153	0.0017	0.0001	
	4	0.9957	0.9274	0.8424	0.7237	0.4382	0.1938	0.0573	0.0095	0.0006	0.0000
	5	0.9995	0.9806	0.9456	0.8822	0.6652	0.3872	0.1582	0.0386	0.0039	0.0001
	6	0.9999	0.9961	0.9857	0.9614	0.8418	0.6128	0.3348	0.1178	0.0194	0.0005
	7	1.0000	0.9994	0.9972	0.9905	0.9427	0.8062	0.5618	0.2763	0.0726	0.0043
	8		0.9999	0.9996	0.9983	0.9847	0.9270	0.7747	0.5075	0.2054	0.0256
	9		1.0000	1.0000	0.9998	0.9972	0.9807	0.9166	0.7472	0.4417	0.1109
	10				1.0000	0.9997	0.9968	0.9804	0.9150	0.7251	0.3410
	11					1.0000	0.9998	0.9978	0.9862	0.9313	0.7176
	12						1.0000	1.0000	1.0000	1.0000	1.0000
13	0	0.2542	0.0550	0.0238	0.0097	0.0013	0.0001	0.0000			
	1	0.6213	0.2336	0.1267	0.0637	0.0126	0.0017	0.0001	0.0000		
	2	0.8661	0.5017	0.3326	0.2025	0.0579	0.0112	0.0013	0.0001		
	3	0.9658	0.7473	0.5843	0.4206	0.1686	0.0461	0.0078	0.0007	0.0000	
	4	0.9935	0.9009	0.7940	0.6543	0.3530	0.1334	0.0321	0.0040	0.0002	
	5	0.9991	0.9700	0.9198	0.8346	0.5744	0.2905	0.0977	0.0182	0.0012	0.0000
	6	0.9999	0.9930	0.9757	0.9376	0.7712	0.5000	0.2288	0.0624	0.0070	0.0001
	7	1.0000	0.9988	0.9944	0.9818	0.9023	0.7095	0.4256	0.1654	0.0300	0.0009
	8		0.9998	0.9990	0.9960	0.9679	0.8666	0.6470	0.3457	0.0991	0.0065
	9		1.0000	0.9999	0.9993	0.9922	0.9539	0.8314	0.5794	0.2527	0.0342
	10			1.0000	0.9999	0.9987	0.9888	0.9421	0.7975	0.4983	0.1339
	11				1.0000	0.9999	0.9983	0.9874	0.9363	0.7664	0.3787
	12					1.0000	0.9999	0.9987	0.9903	0.9450	0.7458
	13						1.0000	1.0000	1.0000	1.0000	1.0000
14	0	0.2288	0.0440	0.0178	0.0068	0.0008	0.0001	0.0000			
	1	0.5846	0.1979	0.1010	0.0475	0.0081	0.0009	0.0001			
	2	0.8416	0.4481	0.2811	0.1608	0.0398	0.0065	0.0006	0.0000		
	3	0.9559	0.6982	0.5213	0.3552	0.1243	0.0287	0.0039	0.0002		
	4	0.9908	0.8702	0.7415	0.5842	0.2793	0.0898	0.0175	0.0017	0.0000	
	5	0.9985	0.9561	0.8883	0.7805	0.4859	0.2120	0.0583	0.0083	0.0004	
	6	0.9998	0.9884	0.9617	0.9067	0.6925	0.3953	0.1501	0.0315	0.0024	0.0000
	7	1.0000	0.9976	0.9897	0.9685	0.8499	0.6047	0.3075	0.0933	0.0116	0.0002
	8		0.9996	0.9978	0.9917	0.9417	0.7880	0.5141	0.2195	0.0439	0.0015
	9		1.0000	0.9997	0.9983	0.9825	0.9102	0.7207	0.4158	0.1298	0.0092
	10			1.0000	0.9998	0.9961	0.9713	0.8757	0.6448	0.3018	0.0441
	11				1.0000	0.9994	0.9935	0.9602	0.8392	0.5519	0.1584
	12					0.9999	0.9991	0.9919	0.9525	0.8021	0.4154
	13					1.0000	0.9999	0.9992	0.9932	0.9560	0.7712
	14						1.0000	1.0000	1.0000	1.0000	1.0000

تابع جدول قيم دالة التوزيع الحداني
Binomial Distribution

∑_{ℓ=0}^k b(ℓ;n,p) = ∑_{ℓ=0}^k \binom{n}{ℓ} \cdot p^ℓ \cdot (1-p)^{n-ℓ}

n	k	p									
		0.10	0.20	0.25	0.30	0.40	0.50	0.60	0.70	0.80	0.90
15	0	0.2059	0.0352	0.0134	0.0047	0.0005	0.0000				
	1	0.5490	0.1671	0.0802	0.0353	0.0052	0.0005	0.0000			
	2	0.8159	0.3980	0.2361	0.1268	0.0271	0.0037	0.0003	0.0000		
	3	0.9444	0.6482	0.4613	0.2969	0.0905	0.0176	0.0019	0.0001		
	4	0.9873	0.8358	0.6865	0.5155	0.2173	0.0592	0.0093	0.0007	0.0000	
	5	0.9978	0.9389	0.8516	0.7216	0.4032	0.1509	0.0338	0.0037	0.0001	
	6	0.9997	0.9819	0.9434	0.8689	0.6098	0.3036	0.0950	0.0152	0.0008	
	7	1.0000	0.9958	0.9827	0.9500	0.7869	0.5000	0.2131	0.0500	0.0042	0.0000
	8		0.9992	0.9958	0.9848	0.9050	0.6964	0.3902	0.1311	0.0181	0.0003
	9		0.9999	0.9992	0.9963	0.9662	0.8491	0.5968	0.2784	0.0611	0.0022
	10		1.0000	0.9999	0.9993	0.9907	0.9408	0.7827	0.4845	0.1642	0.0127
	11			1.0000	0.9999	0.9981	0.9824	0.9095	0.7031	0.3518	0.0556
	12				1.0000	0.9997	0.9963	0.9729	0.8732	0.6020	0.1841
	13					1.0000	0.9995	0.9948	0.9647	0.8329	0.4510
	14						1.0000	0.9995	0.9953	0.9648	0.7941
	15							1.0000	1.0000	1.0000	1.0000
16	0	0.1853	0.0281	0.0100	0.0033	0.0003	0.0000				
	1	0.5147	0.1407	0.0635	0.0261	0.0033	0.0003	0.0000			
	2	0.7892	0.3518	0.1971	0.0994	0.0183	0.0021	0.0001			
	3	0.9316	0.5981	0.4050	0.2459	0.0651	0.0106	0.0009	0.0000		
	4	0.9830	0.7982	0.6302	0.4499	0.1666	0.0384	0.0049	0.0003		
	5	0.9967	0.9183	0.8103	0.6598	0.3288	0.1051	0.0191	0.0016	0.0000	
	6	0.9995	0.9733	0.9204	0.8247	0.5272	0.2272	0.0583	0.0071	0.0002	
	7	0.9999	0.9930	0.9729	0.9256	0.7161	0.4018	0.1423	0.0257	0.0015	0.0000
	8	1.0000	0.9985	0.9925	0.9743	0.8577	0.5982	0.2839	0.0744	0.0070	0.0001
	9		0.9998	0.9984	0.9929	0.9417	0.7728	0.4728	0.1753	0.0267	0.0005
	10		1.0000	0.9997	0.9984	0.9809	0.8949	0.6712	0.3402	0.0817	0.0033
	11			1.0000	0.9997	0.9951	0.9616	0.8334	0.5501	0.2018	0.0170
	12				1.0000	0.9991	0.9894	0.9349	0.7541	0.4019	0.0684
	13					0.9999	0.9979	0.9817	0.9006	0.6482	0.2108
	14					1.0000	0.9997	0.9967	0.9739	0.8593	0.4853
	15						1.0000	0.9997	0.9967	0.9719	0.8147
	16							1.0000	1.0000	1.0000	1.0000

تابع جدول قيم دالة التوزيع الحداني

Binomial Distribution

$$\sum_{\ell=0}^k \mathbf{b}(\ell;n,p) = \sum_{\ell=0}^k \binom{n}{\ell} \cdot p^{\ell} \cdot (1-p)^{n-\ell}$$

n	k	p									
		0.10	0.20	0.25	0.30	0.40	0.50	0.60	0.70	0.80	0.90
17	0	0.1668	0.0225	0.0075	0.0023	0.0002	0.0000				
	1	0.4818	0.1182	0.0501	0.0193	0.0021	0.0001	0.0000			
	2	0.7618	0.3096	0.1637	0.0774	0.0123	0.0012	0.0001			
	3	0.9174	0.5489	0.3530	0.2019	0.0464	0.0064	0.0005	0.0000		
	4	0.9779	0.7582	0.5739	0.3887	0.1260	0.0245	0.0025	0.0001		
	5	0.9953	0.8943	0.7653	0.5968	0.2639	0.0717	0.0106	0.0007	0.0000	
	6	0.9992	0.9623	0.8929	0.7752	0.4478	0.1662	0.0348	0.0032	0.0001	
	7	0.9999	0.9891	0.9598	0.8954	0.6405	0.3145	0.0919	0.0127	0.0005	
	8	1.0000	0.9974	0.9876	0.9597	0.8011	0.5000	0.1989	0.0403	0.0026	0.0000
	9		0.9995	0.9969	0.9873	0.9081	0.6855	0.3595	0.1046	0.0109	0.0001
	10		0.9999	0.9994	0.9968	0.9652	0.8338	0.5522	0.2248	0.0377	0.0008
	11		1.0000	0.9999	0.9993	0.9894	0.9283	0.7361	0.4032	0.1057	0.0047
	12			1.0000	0.9999	0.9975	0.9755	0.8740	0.6113	0.2418	0.0221
	13				1.0000	0.9995	0.9936	0.9536	0.7981	0.4511	0.0826
	14					0.9999	0.9988	0.9877	0.9226	0.6904	0.2382
	15					1.0000	0.9999	0.9979	0.9807	0.8818	0.5182
	16						1.0000	0.9998	0.9977	0.9775	0.8332
	17							1.0000	1.0000	1.0000	1.0000
18	0	0.1501	0.0180	0.0056	0.0016	0.0001	0.0000				
	1	0.4503	0.0991	0.0395	0.0142	0.0013	0.0001				
	2	0.7338	0.2713	0.1353	0.0600	0.0082	0.0007	0.0000			
	3	0.9018	0.5010	0.3057	0.1646	0.0328	0.0038	0.0002			
	4	0.9718	0.7164	0.5187	0.3327	0.0942	0.0154	0.0013	0.0000		
	5	0.9936	0.8671	0.7175	0.5344	0.2088	0.0481	0.0058	0.0003		
	6	0.9988	0.9487	0.8610	0.7217	0.3743	0.1189	0.0203	0.0014	0.0000	
	7	0.9998	0.9837	0.9431	0.8593	0.5634	0.2403	0.0576	0.0061	0.0002	
	8	1.0000	0.9957	0.9807	0.9404	0.7368	0.4073	0.1347	0.0210	0.0009	
	9		0.9991	0.9946	0.9790	0.8653	0.5927	0.2632	0.0596	0.0043	0.0000
	10		0.9998	0.9988	0.9939	0.9424	0.7597	0.4366	0.1407	0.0163	0.0002
	11		1.0000	0.9998	0.9986	0.9797	0.8811	0.6257	0.2783	0.0513	0.0012
	12			1.0000	0.9997	0.9942	0.9519	0.7912	0.4656	0.1329	0.0064
	13				1.0000	0.9987	0.9846	0.9058	0.6673	0.2836	0.0282
	14					0.9998	0.9962	0.9672	0.8354	0.4990	0.0982
	15					1.0000	0.9993	0.9918	0.9400	0.7287	0.2662
	16						0.9999	0.9987	0.9858	0.9009	0.5497
	17						1.0000	0.9999	0.9984	0.9820	0.8499
	18							1.0000	1.0000	1.0000	1.0000

تابع جدول قيم دالة التوزيع الحداني

Binomial Distribution

$$\sum_{\ell=0}^k \mathbf{b}(\ell;n,p) = \sum_{\ell=0}^k \binom{n}{\ell} \cdot p^{\ell} \cdot (1-p)^{n-\ell}$$

n	k	p									
		0.10	0.20	0.25	0.30	0.40	0.50	0.60	0.70	0.80	0.90
19	0	0.1351	0.0144	0.0042	0.0011	0.0001					
	1	0.4203	0.0829	0.0310	0.0104	0.0008	0.0000				
	2	0.7054	0.2369	0.1113	0.0462	0.0055	0.0004	0.0000			
	3	0.8850	0.4551	0.2631	0.1332	0.0230	0.0022	0.0001			
	4	0.9648	0.6733	0.4654	0.2822	0.0696	0.0096	0.0006	0.0000		
	5	0.9914	0.8369	0.6678	0.4739	0.1629	0.0318	0.0031	0.0001		
	6	0.9983	0.9324	0.8251	0.6655	0.3081	0.0835	0.0116	0.0006		
	7	0.9997	0.9767	0.9225	0.8180	0.4878	0.1796	0.0352	0.0028	0.0000	
	8	1.0000	0.9933	0.9713	0.9161	0.6675	0.3238	0.0885	0.0105	0.0003	
	9		0.9984	0.9911	0.9674	0.8139	0.5000	0.1861	0.0326	0.0016	
	10		0.9997	0.9977	0.9895	0.9115	0.6762	0.3325	0.0839	0.0067	0.0000
	11		1.0000	0.9995	0.9972	0.9648	0.8204	0.5122	0.1820	0.0233	0.0003
	12			0.9999	0.9994	0.9884	0.9165	0.6919	0.3345	0.0676	0.0017
	13			1.0000	0.9999	0.9969	0.9682	0.8371	0.5261	0.1631	0.0086
	14				1.0000	0.9994	0.9904	0.9304	0.7178	0.3267	0.0352
	15					0.9999	0.9978	0.9770	0.8668	0.5449	0.1150
	16					1.0000	0.9996	0.9945	0.9538	0.7631	0.2946
	17						1.0000	0.9992	0.9896	0.9171	0.5797
	18							0.9999	0.9989	0.9856	0.8649
	19							1.0000	1.0000	1.0000	1.0000
20	0	0.1216	0.0115	0.0032	0.0008	0.0000					
	1	0.3917	0.0692	0.0243	0.0076	0.0005	0.0000				
	2	0.6769	0.2061	0.0913	0.0355	0.0036	0.0002				
	3	0.8670	0.4114	0.2252	0.1071	0.0160	0.0013	0.0000			
	4	0.9568	0.6296	0.4148	0.2375	0.0510	0.0059	0.0003			
	5	0.9887	0.8042	0.6172	0.4164	0.1256	0.0207	0.0016	0.0000		
	6	0.9976	0.9133	0.7858	0.6080	0.2500	0.0577	0.0065	0.0003		
	7	0.9996	0.9679	0.8982	0.7723	0.4159	0.1316	0.0210	0.0013	0.0000	
	8	0.9999	0.9900	0.9591	0.8867	0.5956	0.2517	0.0565	0.0051	0.0001	
	9	1.0000	0.9974	0.9861	0.9520	0.7553	0.4119	0.1275	0.0171	0.0006	
	10		0.9994	0.9961	0.9829	0.8725	0.5881	0.2447	0.0480	0.0026	0.0000
	11		0.9999	0.9991	0.9949	0.9435	0.7483	0.4044	0.1133	0.0100	0.0001
	12		1.0000	0.9998	0.9987	0.9790	0.8684	0.5841	0.2277	0.0321	0.0004
	13			1.0000	0.9997	0.9935	0.9423	0.7500	0.3920	0.0867	0.0024
	14				1.0000	0.9984	0.9793	0.8744	0.5836	0.1958	0.0113
	15					0.9997	0.9941	0.9490	0.7625	0.3704	0.0432
	16					1.0000	0.9987	0.9840	0.8929	0.5886	0.1330
	17						0.9998	0.9964	0.9645	0.7939	0.3231
	18						1.0000	0.9995	0.9924	0.9308	0.6083
	19							1.0000	0.9992	0.9885	0.8784
	20								1.0000	1.0000	1.0000

جدول قيم العشوائية

Random Values

67835 63314 50162 36738 25014 15460 11730 76548 05393 96770 56087 40875 13351 93994 22375 00953 85423 60698 01898 61414	00551 24909 31894 39333 00767 45637 79839 75532 28704 04231 40875 13351 93994 93994 36009 76548 05393 67170 56087 99410
76548 93547 24769 09404 19574 71565 33413 81652 45554 27931 05393 96770 56087 40875 13351 93994 22375 00953 22375 00953	33015 19155 11715 48992 64998 87080 48660 31288 00086 48245 56087 00953 22375 00953 99410 16210 22375 00953 22375 00953
00619 85423 60698 01898 61414 83525 76548 05393 96770 22909 29563 44018 64732 93589 61098 04393 48245 56087 40875 13351	82310 18163 63495 04470 78754 90775 10819 56797 33751 61414 83525 76548 05393 48245 56087 99410 04231 40875 13351 93994
52975 58993 99410 48245 56087 41383 31555 12639 82667 10324 15457 65515 19251 41642 36345 41404 81110 64109 09497 76235	37774 37953 78837 12538 67439 94914 62844 92337 99695 99410 48245 56087 61414 83525 76548 05393 64109 09497 76235 16210
25640 67257 18671 66658 30818 58353 03448 37390 96328 04231 40875 13351 93994 48245 56087 99410 22375 00953 22375 00953	50061 42539 14812 07389 87891 76255 32072 80083 63868 85423 60698 01898 58993 99410 48245 56087 93994 36009 76548 05393
60492 78654 51108 66992 93183 56920 47196 12452 38234 96328 04231 40875 13351 41383 31555 12639 82667 93994 36009 76548	33015 19155 11715 48992 64998 87080 48660 31288 00086 48245 56087 00953 22375 00953 99410 16210 22375 00953 22375 00953

جدول قيم العشوائية
Random Values

36009 76548 05393 6770 56087 40875 13351 93994 22375 00953 95892 36962 76431 81594 95848 04231 13604 75339 01898 61414	73152 14511 85285 14536 11649 86348 01898 61414 83525 76548 05393 96770 56087 76431 81594 95848 04231 40875 13351 93994
93547 24769 09404 19574 71565 33413 81652 45554 27931 12074 98551 37895 39941 21225 93629 41469 16812 81542 04231 40875	12074 98551 37895 39941 21225 93629 41469 16812 81542 04231 40875 13351 93994 36009 76548 05393 67701 85423 60698 01898
41383 31555 12639 82667 74624 36348 77319 73408 58993 99410 48245 56087 22375 00953 22375 00953 04231 40875 13351 93994	64109 09497 76235 16210 89717 65997 02760 24359 36009 76548 05393 67705 71565 33413 81652 45554 56087 40875 13351 93994
10081 04231 40875 13351 93994 73152 14511 85285 14536 82454 76810 15941 84602 14493 36932 46728 71183 16210 64109 09497	86576 86944 93296 66456 47679 66810 41045 82830 47617 76235 16210 16210 25014 15460 11730 76548 04231 40875 13351 93994
57550 49620 98480 64451 29275 57669 34075 16451 42885 58993 99410 48245 56087 99410 48245 56087 00619 85423 60698 01898	68816 37643 19959 46784 66125 94932 40350 62533 73603 61414 83525 76548 05393 04231 40875 13351 93994 83525 76548 05393
19184 64164 66962 40434 60602 82175 25471 76107 90832 00619 85423 60698 01898 48245 56087 61414 83525 76548 05393 22375	17612 65522 80607 02407 06098 92917 55558 15520 27038 14536 82454 76810 15941 96328 04231 40875 13351 76235 16210 16210

جدول كولموغوراف - سميرونوف لاختبار جودة توفيق التوزيعات

Kolmogorov-Smirnov Table for Test of Goodness of Fit

حجم العينة n	مستوى الأهمية α				
	0.01	0.05	0.10	0.15	0.20
1	0.995	0.975	0.950	0.925	0.900
2	0.929	0.842	0.776	0.726	0.684
3	0.829	0.708	0.642	0.597	0.565
4	0.734	0.624	0.564	0.525	0.494
5	0.669	0.563	0.510	0.474	0.446
6	0.618	0.470	0.470	0.436	0.410
7	0.577	0.486	0.438	0.405	0.301
8	0.543	0.457	0.411	0.301	0.358
9	0.514	0.432	0.388	0.360	0.339
10	0.486	0.409	0.368	0.342	0.322
11	0.468	0.391	0.352	0.326	0.307
12	0.450	0.375	0.338	0.313	0.295
13	0.433	0.361	0.325	0.302	0.284
14	0.418	0.319	0.314	0.292	0.274
15	0.404	0.338	0.304	0.203	0.266
16	0.391	0.328	0.295	0.274	0.258
17	0.300	0.318	0.286	0.266	0.250
18	0.370	0.309	0.278	0.259	0.244
19	0.361	0.301	0.272	0.252	0.237
20	0.352	0.294	0.264	0.246	0.231
25	0.317	0.264	0.245	0.227	0.215
30	0.285	0.242	0.238	0.207	0.196
35	0.290	0.242	0.218	0.192	0.181

لحساب القيمة الحرجة المتعلقة باختبار كولموغوراف-سميرونوف لجودة التوفيق عندما تكون $n < 35$ تُستخدم العلاقة الآتية:

$$ks_n = \frac{\sqrt{-0.5 \cdot \ln\left(\frac{\alpha}{2}\right)}}{\sqrt{n}}$$

ملخص

لتوزيعات احتمالية شهيرة

Summary of Famous Probability Distributions

توزيعات احتمالية متقطعة

Discrete Probability Distributions

اسم التوزيع	التباين $\text{var}X =$	الدالة المولدة للعزوم $\mathbf{M}_X(t) =$	الدالة المميزة $\varphi_X(t) =$
وحيد النقطة One point	0	e^{ct}	$e^{c \, i \, t}$
ثنائي النقطة Tow Point	$(x_1 - x_2)^2 p(1 - p)$	$p e^{tx_1} + (1 - p) e^{tx_2}$	$p e^{i t x_1} + (1 - p) e^{i t x_2}$
المنتظم المتقطع Discrete Uniform	$\frac{1}{n} \sum_{k=1}^n x_k^2 - \left(\frac{1}{n} \sum_{k=1}^n x_k \right)^2$	$\frac{1}{n} \sum_{k=1}^n e^{t x_k}$	$\frac{1}{n} \sum_{k=1}^n e^{i t x_k}$
الحدائي Binomial	$n p(1 - p)$	$\left[1 - p (1 - e^t) \right]^n$	$\left[1 - p (1 - e^{i t}) \right]^n$
الهندسي Geometric	$\frac{1 - p}{p^2}$	$\frac{p e^t}{1 - e^t (1 - p)}$	$\frac{p e^{i t}}{1 - e^{i t} (1 - p)}$
الحدائي السالب Negative Binomial	$\frac{n p}{(1 - p)^2}$	$\left(\frac{1 - p}{1 - p e^t} \right)^n$	$\left(\frac{1 - p}{1 - p e^{i t}} \right)^n$
فوق الهندسي Hyper Geometric	$\frac{n M (N - M) (N - n)}{N^2 (N - 1)}$	لا تُعطى بدلالة دوال أولية بسيطة	لا تُعطى بدلالة دوال أولية بسيطة
بواسون Poisson	λ	$e^{\lambda (e^t - 1)}$	$e^{\lambda (e^{i t} - 1)}$

توزيعات احتمالية متقطعة

Discrete Probability Distributions

اسم التوزيع	المعالم Parameters	دالة الكتلة الاحتمالية $P(X = x) =$	التوقع الرياضي $\mathbf{E} X =$
وحيد النقطة One point	$\mathbb{R} \ni c$	$\mathbf{I}_{\{c\}}(x)$	$\mathbf{I}_{\{c\}}(x)$
ثنائي النقطة Tow Point	$1 > p > 0$	$p \cdot \mathbf{I}_{\{x_1\}}(x) + (1 - p) \cdot \mathbf{I}_{\{x_2\}}(x)$	$x_1 p + x_2 (1 - p)$
المنتظم المتقطع Discrete Uniform	$n \in \mathbb{N}$	$\frac{1}{n} \cdot \mathbf{I}_{\{x_1, x_2, \dots, x_n\}}(k)$	$\frac{1}{n} \sum_{i=1}^n x_i$
الحدائي Binomial	$n \in \mathbb{N}$ $1 > p > 0$	$\binom{n}{x} \cdot p^x \cdot (1 - p)^{n-x} \cdot \mathbf{I}_{\mathbb{N}_n^o}(x)$	$n \cdot p$
الهندسي Geometric	$1 > p > 0$	$p \cdot (1 - p)^{x-1} \cdot \mathbf{I}_{\mathbb{N}}(x)$	$\frac{1}{p}$
الحدائي السالب Negative Binomial	$n \in \mathbb{N}$ $1 > p > 0$	$\binom{x+n-1}{x} \cdot p^n \cdot (1 - p)^x \cdot \mathbf{I}_{\mathbb{N}^o}(x)$	$\frac{n(1 - p)}{p}$
فوق الهندسي Hyper Geometric	$N, M, n \in \mathbb{N}$ $1 \leq M, n \leq N$	$\binom{M}{x} \cdot \binom{N - M}{n - x} \cdot \binom{N}{n}^{-1} \cdot \mathbf{I}_D(x)$ $D := \mathbb{N}_M^o \cap [\max\{0, n - N + M\}, \min\{n, M\}]$	$\frac{n \cdot M}{N}$
بواسون Poisson	$\lambda > 0$	$\frac{\lambda^x}{x!} \mathbf{e}^{-\lambda} \cdot \mathbf{I}_{\mathbb{N}^o}(x)$	λ

توزيعات احتمالية مستمرة

Continuous Probability Distributions

اسم التوزيع	التباين $\text{var } X =$	الدالة المولدة للعزوم $M_X(t) =$	الدالة المميزة $\varphi_X(t) =$
المنتظم المستمر Continues Uniform	$\frac{b^2 - a^2}{12}$	$\frac{e^{tb} - e^{ta}}{(b - a)t}$	$\frac{e^{itb} - e^{ita}}{(b - a)it}$
الأسّي Exponential	$\frac{1}{\lambda^2}$	$\frac{\lambda}{\lambda - t}$	$\frac{\lambda}{\lambda - it}$
الطبيعي Discrete Uniform	σ^2	$\exp \left[\mu t + \frac{1}{2} t^2 \sigma^2 \right]$	$\exp \left[\mu it - \frac{1}{2} t^2 \sigma^2 \right]$
ستودنت Binomial	$\frac{n}{n - 2}$ <i>for</i> $n > 2$	لا يمكن إعطاؤها بوساطة دوال أوليّة بسيطة	لا يمكن إعطاؤها بوساطة دوال أوليّة بسيطة
كاي مربع Geometric	$2n$	$(1 + 2t)^{-\frac{n}{2}}$	$(1 - 2t)^{-\frac{n}{2}}$
فيشر Negative Binomial	$\frac{2n^2(m + n - 2)}{m(n - 2)^2(n - 4)}$ <i>for</i> $n > 4$	لا يمكن إعطاؤها بوساطة دوال أوليّة بسيطة	لا يمكن إعطاؤها بوساطة دوال أوليّة بسيطة
كوشي Cauchy	غير موجود	غير موجودة	$\exp \left[\mu it - \lambda t \right]$
المنطقي Logistic	$\frac{\sigma \pi^2}{3}$	$e^{\mu t} \beta(1 - \sigma, 1 + \sigma t)$ <i>for</i> $\sigma t \in (-1, 1)$	$e^{i\mu t} \frac{\pi \sigma t}{\sinh(\pi \sigma t)}$

توزيعات احتمالية مستمرة
Continuous Probability Distributions

اسم التوزيع	المعالم Parameters	دالة الكثافة الاحتمالية $f_X(x) =$	التوقع الرياضي $E X =$
المنتظم المستمر Continues Uniform	$a, b \in \mathbb{R}$ $a < b$	$\frac{1}{b-a} \mathbf{I}_{[a, b]}(x)$	$\frac{a+b}{2}$
الأسّي Exponential	$\lambda > 0$	$\lambda e^{-\lambda x} \cdot \mathbf{I}_{[0, +\infty)}(x)$	$\frac{1}{\lambda}$
الطبيعي Discrete Uniform	$\mu \in \mathbb{R}$ $\sigma > 0$	$\frac{1}{\sigma \sqrt{2\pi}} \exp \left[-\frac{(x-\mu)^2}{2\sigma^2} \right]$	μ
سنودنت Binomial	$n \in \mathbb{N}$ عدد درجات الحرية	$\frac{\Gamma(\frac{n+1}{2}) \cdot (1 + \frac{x^2}{n})^{-\frac{n+1}{2}}}{\sqrt{n\pi} \cdot \Gamma(\frac{n}{2})}$	0
كاي مربع Geometric	$n \in \mathbb{N}$ عدد درجات الحرية	$\frac{(\frac{1}{2})^{\frac{n}{2}}}{\Gamma(\frac{n}{2})} x^{\frac{n}{2}-1} e^{-\frac{x}{2}} \cdot \mathbf{I}_{(0, \infty)}(x)$	n
فيشر Negative Binomial	$n \in \mathbb{N}$ $1 > p > 0$	$\frac{\left(\frac{m}{n}\right)^{\frac{m}{2}} x^{\frac{m}{2}-1}}{\beta(\frac{m}{2}, \frac{n}{2})} \left(1 + \frac{mx}{n}\right)^{-\frac{m+n}{2}} \cdot \mathbf{I}_{[0, \infty)}(x)$	$\frac{n}{n-2}$ for $n > 2$
كوشي Cauchy	$\mu \in \mathbb{R}$ $\lambda > 0$	$\frac{\lambda}{\pi \left(\lambda^2 + (x-\mu)^2 \right)}$	غير موجود
المنطقي Logistic	$\mu \in \mathbb{R}$ $\sigma > 0$	$\frac{\exp \left[-\frac{x-\mu}{\sigma} \right]}{\sigma \left(1 + \exp \left[-\frac{x-\mu}{\sigma} \right] \right)^2}$	μ

المراجع

- 1-**ALEXANDEROFF, P.S.**; Einfürung in die Mengenlehre und in die allgemeine Topologie; VEB Deutscher-Verlag der Wessenschaften Berlin; **1984**.
- 2-**ANDERSON & SWEENEY & WILLIAMS**; Statistics for Business and Economics; South Western Educational Publishing; **2011**.
- 3-**ATHANASIOS PAPOULIS S. & UNNIKRISHNA PILLAI**; Probability, Random Variables And Stochastic Processes Fourth Edition; McGraw-Hill Companies, Inc; **2002**.
- 4-**ATHREYA, K.B. & LAHIRI, S.N.**; Measure Theory and Probability Theory; Springer Texts in Statistics, Springer-Verlag, NY; **2006**.
- 5-**BAUER, H.**; Probability Theory and Elements of Measure Theory- English transl; Holt-Rinehart-Winston, NY; **1972**.
- 6-**BEYER, O. & HACKEL, H. & PIEPER, V. & TIEDGE, J.**; Wahrschichkeitsrechnung und mathematische Statistik; BSB B. G. Teubner Verlagsgesellschaft Leipzig; **1985**.
- 7-**BHATTACHARYA, R & WAYMIRE, E.C. & AXLER, S. & RIBET, K.A.**; A Basic Course in Probability Theory; Springer Science and Business Media, Inc; **2007**.
- 8-**BILLINGSLEY, P.**; Probability and Measure, 3rd ed; Wiley, NY; **1995**.
- 9-**BJÖRN SCHELTER & MATTHIAS WINTERHADLER & JENS TIMMER**; Handbook of Time Series Analysis; WILEY-VCH Verlag GmbH & Co. KGaA, Weinheim; **2006**.
- 10-**BOROWKOW, A.A.**; Wahrschriclichkeitstheorie; Alademie Verlag . Berlin; **1976**.
- 11-**BROCKWELL, P. & DAVIS, R.**; Time Series: Theory and Methods; ; Springer- Verlag New York Inc.; **1987**.
- 12-**BROCKWELL, P. & DAVIS, R.**; Introduction to Time Series and Forecasting - Second Edition; Springer-Verlag New York, Inc.; **2002**.
- 13-**CHARLES, W. THERRIEN & MURALI TUMMALA**; Probability for electrical and computer engineers - CRC Press; Roca Raton , New York; **2004**.
- 14-**CHRISTIAN HESSE**; Angewandte Wahrscheinlichkeitstheorie; Friedr. Vieweg und Sohn Verlagsgesellschaft - Germany; **2003**.
- 15-**CHRISTOS G. CASSANDRAS & STÉPHANE LAFORTUNE**; Introduction to Discrete Event Systems - Second Edition; Springer Science+Business Media, LLC; **2008**.

- 16-**DALLMANN, H. & ELSETER, K.-H**; Einführung in die höhere Mathematik- Band I+II; VEB Gustav Fischer Verlag Jena; **1981**.
- 17-**DAVID R. ANDERSON & DENNIS J. SWEENEY & THOMAS A. WILLIAMS**; Statistics for Business and Economics - 11e; South-Western, Cengage Learning; **2011**.
- 18-**De COURSEY, W.J.**; Statistics and Probability for Engineering Applications With Microsoft® Excel; Elsevier Science (USA); **2003**.
- 19-**DIMITRI P. BERTSEKAS & JOHN N. TSITSIKLIS**; Introduction to Probability; Dimitri P. Bertsekas and John N. Tsitsiklis; **2002**.
- 20-**DOUGLAS C. MONTGOMERY & GEORGE C. RUNGER**; Applied Statistics and Probability for Engineers -Third Edition; John Wiley & Sons, Inc; **2003**.
- 21-**DOUGLAS C. MONTGOMERY & CHERYL L. JENNINGS & MURAT KULAHCI**; Introduction to Time Series Analysis and Forecasting; John Wiley & Sons. Inc; **2008**.
- 22-**EGGERMONT P.P.B. LARICCIA, V.N.**; Maximum Penalized Likelihood Estimation, Volume II: Regression; Springer Science+Business Media, LLC; **2009**.
- 23-**ENDERTON, H. B.**; Elements of Set Theory; Academic Press College Division New York; **1977**.
- 24-**FISZ, M.**; Wahrscheinlichkeitsrechnung und mathematische Statistik; VEB Deutscher Verlag der Wissenschaften, Berlin; **1980**.
- 25-**GEBHARD KIRCHGÄSSER & JÜRGEN WOLTERS**; Introduction to Modern Time Series Analysis; Springer-Verlag Berlin Heidelberg; **2007**.
- 26-**GNEDENKO, B. W.**;Lehrbuch der Wahrscheinlichkeitsrechnung; Akademie – Verlag. Berlin; **1987**.
- 27-**GNEDENKO,B.W. & LOMONOSSOW & KONIG, D. and another author**; Handbuch der Wahrscheinlichkeitsrechnung (I + II); Akademie – Verlag. Berlin; **1987**.
- 28-**GRIMMETT, G.R. & STRZAKER, D.R**; Probability and Random Processes; Oxford Science Publications; **1982**.
- 29-**HANS-OTTO GEORGII**; Stochastik; Walter de Gruyter - Berlin . New York; **2002**.
- 30-**IBRAGIMOV, I.A. & ROZANOV, Y.A.**; Gaussian random processes; Spriger – Verlag – New York-Heidelberg-Berlin; **1970**.
- 31-**KALLENBERG, O.**; Foundations of Modern Probability, 2nd ed.; Springer-Verlag, NY; **2001**.
- 32-**KAUSCH, HEIKO**; Zeitreihenprognose; VDM Verlag. München; **2007**.
- 33-**KRAUSE, B. & METZLER, P.**; Angewadte Statistik; VEB Deutscher-Verlag der Wessenschaften Berlin; **1988**.
- 34-**KREIß JENS-PETER**; Einfhührung in die Zeitreihenanalyse; Verlag Gmbh. Deutschland; **2006**.
- 35-**KRISTIAN, H.**; Angewandte Wahrscheinlichkeitsthorie; Friedr, Vieweg and Sohn, verlagsgesellschaft mbH, Braunschweig , Wiesbaden; **2003**.
- 36-**LANDDE ,G .S & SAMBANDHAM ,M.**; Stochastic Versus Deterministic System of differential equation; Marcel Dekker INC. New York – Basel; **2004**.
- 37-**LARSEN, R. J. & MARX , M. L.**; An introduction to Mathematical Statistics and its Applications; Prentice-Hall International , Inc. USA; **1993**.

- 38-**LEONID, B. KORALOV & YAKOV, G. SINA**; Theory of Probability and Random Processes - Second Edition; Springer-Verlag Berlin Heidelberg; **2007**.
- 39-**LOEVE, M.**; Probability Theory (I + II); Springer, New York; **1978**.
- 40-**MAIBAUM, G**; Wahrscheinlichkeitstheorie und mathematische Statistik; VEB Deutscher Verlag der Wessenschaften Berlin; **1980**.
- 41-**MARVIN, K. SIMON**; Probability Distributions Involving Gaussian Random Variables; Springer Science +Business Media, LLC; **2002**.
- 42-**MICHEL , H.**; Mass – und Integrationstheorie; VEB Deutscher Verlag der Wessenschaften Berlin; **1978**.
- 43-**MIKE LEVAN**; Probability and Statistics; McGraw- Hill Companies; **2001**.
- 44-**RABI BHATTACHARYA & EDWARD C. WAYMIRE**; A Basic Course in Probability Theory; Springer Science+Business Media, Inc.; **2007**.
- 45-**RASCH, D.**; Einfurung in die mathematische Statistik Band I; VEB Deutscher Verlag der Wessenschaften, Berlin; **1984**.
- 46-**RENYI, A**; Wahrscheinlichkeitsrechnung; VEB Deutscher Verlag der Wessenschaften Berlin; **1979**.
- 47-**RICHARD J. LARSEN & MORRIS L. MARX**; Introduction to Mathematical Statistics and Its Applications - 5/E; Pearson • Cloth, 768 pp; **2012**.
- 48-**ROBERT H. SHUMWAY & DAVID S. STOFFER**; Time Series Analysis and Its Applications; Springer Science+Business Media, LLC; **2006**.
- 49-**RONALD E. WALPOLE & RAYMOND H. MYERS**; Sharon L. Myers; Keying Ye; Probability & Statistics for Engineers & Scientists – Ninth Edition ; Pearson Education, Inc; **2007**.
- 50-**ROSSBERG,H.J. & JESIAK,B. & SIEGEL,G.**; Analytic Methods of Probability Theory; Akademie Verlag Berlin; **1985**.
- 51-**SCNEIDER, I.**; Die Entwicklunug der Wahrscheinlichkeitstheorie von den Anfangen bis **1933**; Akademie-Verlag Berlin; **1989**.
- 52-**SCOTT L. MILLER & DONALD G. CHILDERS**; Probability and Random Processes; Elsevier Inc; **2004**.
- 53-**SIRIJAEV,A.N.**; Wahrscheinlichkeit; VEB Deutscher-Verlag der Wessenschaften Berlin; **1988**.
- 54-**SOONG, T.T.**; Fundamentals of Probability and Statistics for Engineers; John Wiley & Sons Ltd; **2004**.
- 55-**STORM, R**; Wahrscheinlichkeitsrechnung - mathematische Statistik und statistische Qualitätskontrolle; VEB Fachbuchverlag Leipzig; **1986**.
- 56-**TOLOSTOW,G.F**; Maß und Integral; Akademie Verlag Berlin; **1981**.
- 57-**TREVOR HASTIE & ROBERT TIBSHIRANI & JEROME FRIEDMANN**; The Elements of Statistical Learning - Second Edition; Springer Science+Business Media, LLC; **2009**.
- 58-**VENKATARAMA KRISHNAN**; Probability and Random Processes; John Wiley & Sons, Inc.; **2006**.
- 59-**WENTZEL, E.S**; Probability Theory (first steps); Mir Publishers; **1982**.
- 60-**WINKLER, W**; Vorlesungen zur Mathematischen Statistic; BSB B. G. Teubner Verlagsgesellschaft Leipzig; **1983**.
- 61-**YRI SUHOV; MARK KELBERT**; Probability and Statistics by Example: II Markov Chains: a Primer in Random Processes and their Applications; Y. Suhov and M. Kelbert; **2008**.

مراجع عربية

- 62- جلال مصطفى الصياد - الاستدلال الإحصائي - منشورات دار المريح 1993 الرياض.
- 63- حميد عويّد العكله - الجبر الخطي ومبادئ الاحتمالات والإحصاء - لطلاب السنة الأولى فيزياء - منشورات جامعة البعث 2005 حمص، سوريا.
- 64- حميد عويّد العكله - نظرية الاحتمالات (٢) - لطلاب السنة الثالثة إحصاء رياضياتي - منشورات جامعة البعث 2007 حمص، سوريا.
- 65- حميد عويّد العكله - نظرية الاحتمالات - لطلاب السنة الثانية هندسة معلوماتية - منشورات جامعة البعث 2002 حمص، سوريا.
- 66- عبد الله عبد الكريم الشبيحة - أسس نظرية التقدير . جامعة الملك سعود - الرياض، المملكة العربية السعودية 1428 هـ.
- 67- فاندل، والتر - السلاسل الزمنية من الوجهة التطبيقية ونماذج بوكس - جنكنز. تعريب عبد المرحي حامد عزام، دار المريح للنشر، الرياض، المملكة العربية السعودية 1992.

معاجم في الرياضيات

- 68- علي مصطفى بن الأشر - معجم الرياضيات - دار النشر أكاديميا - بيروت، لبنان 1995.
- 69- دنان، ف.م. & باقر، س.ط. & العايدى، ص.ن. & فران، ه.ر. & العقيل، ع.س.هـ. - معجم الرياضيات - منشورات مؤسسة الكويت للتقدم العلمي - الكويت 1990.

دليل الأعلام

الأسماء رتبت بحسب تسلسل ورودها في الكتاب

Chebyshev, Pafnuty Lvovich (1821–1894)	تشبيشيف - رياضياتي روسي
Thorndike, Edward Lee (1874-1949)	ثورنيدك - عالم النفس الأمريكي
Pearson, Karl (1875-1936)	بيرسون - إحصائي إنكليزي
Bowley, Sir Arthur Lyon (1869-1957)	بولي - إحصائي واقتصادي بريطاني
Spearman, Charles Edward (1863-1945)	سبيرمان - إحصائي بريطاني
Anscombe, Francis John (1918-2001)	إنسكومب - إحصائي إنكليزي
Yule, George Udny (1871 –1951)	يول - إحصائي بريطاني
Galton, Sir Francis (1822-1911)	غالتون - عالم وراثة وإحصائي إنكليزي
Legendre, Adrien-Marie (1752-1833)	ليجاندر - رياضياتي فرنسي
Weibull, Ernst Hjalmar Waloddi (1887-1979)	ويبول - مهندس ورياضياتي سويدي
Kolmogorov, Andrey Nikolaevich (1903-1987)	كلموغوراف - رياضياتي روسي
Bernstein, Sergei Natanovich (1880-1968)	برنشتاين - رياضياتي روسي
Borel, Félix Édouard Justin Émile (1871-956)	بوريل - رياضي فرنسي
Glivenko, Valery Ivanovich (1897-1940)	غليفينكو - رياضياتي وفيلسوف أكراني
Shiryaev, Albert Nikolaevich (Born 1934)	شيريايف - رياضياتي وعشوائي روسي
Loève, Michel (1907-1979)	لوفي - إحصائي ورياضياتي فرنسي
Buffon, Georges-Louis (1707-1788)	بوفون - رياضياتي ومؤرخ فرنسي

Laplace, Pierre-Simon, marquis (1749-1827)	لابلاس - رياضياتي فرنسي
Bertrand, Arthur William Russell (1872-1970)	برتراند - رياضياتي وفيلسوف بريطاني
Dirac, Paul Adrien Maurice (1902 –1984)	ديراك - فيزيائي نظري إنكليزي
Bayes, Thomas (1701–1761)	بييز - إحصائي وفيلسوف إنكليزي
Poisson, Siméon Denis (1781-1840)	بواسون - رياضياتي وفيزيائي فرنسي
Radon, Johann Karl August (1887–1956)	رادون - رياضياتي نمساوي
Nikodym, Otto Marcin (1887–1974)	نيكوديم - رياضياتي بولوني
Bernoulli, Jacob (1655-1705)	برنولي - رياضياتي سويسري
Al-Karajī, Abū Bakr ibn Muḥammad ibn al Ḥusayn (953-1029)	الكرخي - فيلسوف ورياضياتي مسلم
Newton, Sir Isaac (1642-1726)	نيوتن - رياضياتي وفيزيائي إنكليزي
Pascal, Blaise (1623-1662)	باسكال - رياضياتي وفيزيائي فرنسي
Moivre, Abraham (1667-1754)	موافير - رياضياتي فرنسي
Gauss, Johann Carl Friedrich (1777-1855)	غاوص - رياضياتي ألماني
Gosset , William Sealy (1876 –1937)	غوسيت - كيميائي ورياضياتي إنكليزي
Cauchy, Augustin-Louis (1789-1857)	كوشي - رياضياتي فرنسي
Fisher, Sir Ronald Aylmer (1890 –1962)	فيشر - إحصائي إنكليزي
Jensen, Johan Ludwig William (1859-1925)	جينسين - رياضياتي ومهندس دانماركي
Schwarz, Karl Hermann Amandus (1843-1921)	شفارتز - فيلسوف ورياضياتي ألماني
Markov, Andrey Andreyevich (1856-1922)	ماركوف - رياضياتي روسي
Lyapunov, Aleksandr Mikhailovich (1857-1918)	ليابانوف - رياضياتي روسي
Bochner, Salomon (1899-1982)	بوخنر - رياضياتي أمريكي (هنغاري الأصل)
Lévy, Paul Pierre (1886-1971)	ليفي - رياضياتي فرنسي
Gnedenko, Boris Vladimirovich (1912-1995)	غنيدينكو - رياضياتي روسي
Tippett, Leonard Henry Caleb (1902-1985)	تيب - إحصائي إنكليزي

Satterthwaite, F. E.	ساتيرثويت - إحصائي
Rao, Calyampudi Radhakrishna (1920)	راو - إحصائي بريطاني (هندي الأصل)
Cramér, Harald (1893-1985)	كرامر - رياضياتي إحصائي سويدي
Geiger, Johannes Wilhelm (1882-1945)	جايجر - فيزيائي ألماني
Marsden, Sir Ernest (1889-1970)	مارسدن - فيزيائي ألماني
Smirnov, Nikolai Vasilyevich (1900-1966)	سميرنوف - رياضياتي روسي
Anderson, Theodore Wilbur (1918-2016)	أندرسون - رياضياتي وإحصائي أمريكي
Darling, Donald Allan (1915-2014)	دارلينغ - إحصائي أمريكي
Halberg, Franz (1919-2013)	هالبرغ - رياضياتي فرنسي
Carli, Gian Rinaldo (1720-1795)	كارلي - اقتصادي ومؤرخ إيطالي
Laspeyres, Ernst Louis Étienne (1834-1913)	لسبيريس - اقتصادي وإحصائي ألماني
Paasche, Hermann (1851-1925)	باشي - اقتصادي وإحصائي ألماني
Stirling, James (1692-1770)	سترلنغ - رياضي أسكتلندي
Fubini, Guido (1879 –1943)	فوبيني - رياضياتي إيطالي

ثبت المصطلحات

عربي < English

	أ	
Trend	٥٦٩	الاتجاه العام
Prior Probability	٢٢١	الاحتمال الأسبق
Failure Probability	٣٠٤	احتمال الفشل
Superior Probability	٢٢١	الاحتمال اللاحق
Success Probability	٣٠٤	احتمال النجاح
Conditional Probability	٢١٨	احتمال شرطي
Mathematical Statistics	١٨٨	الإحصاء الرياضيائي
Statistic	٤٥١	إحصاءة
Maxwell–Boltzmann Statistic	١٩٤	إحصاءة ماكسويل– بولتسمان
Sufficiency Statistic	٤٦٧	الإحصاءة الكافية
Bose – Einstein Statistic	١٩٤	إحصاءة بوزي – أينشتاين
Fermi-Dirac Statistic	١٩٤	إحصاءة فيرمي – ديراك
One -Tailed Test	٥١٨	اختبار أحادي الطرف (أو أحادي الذيل)
Independence Test of two Phenomenon	٥٤٨	اختبار استقلال ظاهرتين
Optimal Test	٥٢٠	الاختبار الأمثل
Homogeneity Test of Distribution	٥٤٤	اختبار التجانس لتوزيع احتمالي
Neumann Deference Test	٥٨٧	اختبار الفرق ل نويمان
Moore Test–Wallis	٥٨٨	اختبار الفروق الأولى ل ووليس- مور
Anderson-Darling Test for Goodness of Fit	٥٤٢	اختبار أندرسون– دارلينغ لجودة التوفيق
Two-Tailed Test	٥١٨	اختبار ثنائي الطرف (أو ثنائي الذيل)
Goodness of Distribution Fit Test	٥٣٧	اختبار جودة توفيق توزيع احتمالي
Staurt-Cox Test	٦٨٨	اختبار سترأوت-كوكس
Non Parametric Test	٥١٣	اختبار غير مَعلمي
Statistical Hypothesis test	٥١٣	اختبار فرضية إحصائية

Chi-Squared Test for Goodness of Fit	٣٣٧	اختبار كاي مربع لجودة التوفيق
Kolmogorov-Smirnov Test	٥٣٩	اختبار كلموغوراف – سميرنوف
Parametric Test	٥١٣	اختبار معلمي
Simple Correlation	١١٧	الارتباط البسيط
Reciprocal Correlation	١١٧	الارتباط التبادلي
Partial Correlation	١١٧	الارتباط الجزئي
Simple Linear Correlation	١١٥	الارتباط الخطي البسيط
Causal Correlation	١١٧	الارتباط السببي
Multiple Correlation	١١٧	الارتباط المتعدد
Spurious Correlation	١١٧	الارتباط الوهمي
Non Linear Correlation	١١٨	الارتباط غير الخطي
Statistical Inference	٤٧٧	الاستدلال الإحصائي
Standardization	٩٥	استيعار أو استقياس (أي جعله معيارياً أو قياسياً)
Independence of Random Variables	٣٥١	استقلال المتغيرات العشوائية
Independence of Events	٢٢٣	استقلال حوادث
Absolute Continuation	٦٦٣	الاستمرار المطلق
Continuous from Below	٢١٥	الاستمرار من الأدنى
Lower Continuity of a measure	٦٥٨	الاستمرار من الأدنى لقياس
Continuous from Above	٢١٥	الاستمرار من الأعلى
Upper Continuity	٦٥٨	الاستمرار من الأعلى
Framework	٤٣٩	الإطار (إطار العمل)
Monotony	٦٥٧	الاطراد
Five Number and the Box plot	١٠٧	الأعداد الخمسة والتمثيل الصندوقي للبيانات
Richest Algebra (or Strongest Algebra)	٢٠٢	أغنى جبر (أو أقوى جبر)
Best Test	٥١٩	أفضل اختبار
Exponential Regression	١٦٨	الانحدار الأسّي
Autoregressive Integrated Moving Average (ARIMA)	٦٠٤	الانحدار الذاتي والمتوسطات المتحركة المتكاملة
Power Regression	١٦٩	انحدار القوى
Simple Fractional Regression	١٦٧	الانحدار الكسري البسيط
Logarithmic Regression	١٦٧	الانحدار اللوغاريتمي
Mean Deviation (or Average Deviations)	٨٣	الانحراف المتوسط (أو متوسط الانحرافات)
Standard Deviation	٨٧	الانحراف المعياري
Relative Standard Deviation	٩٣	الانحراف المعياري النسبي
Systematic Vibrations	٥٦٩	اهتزازات رتيبة
Residual	١٤٥	الباقى

ب		
Imprint of Time Series	٥٦٥	بصمة متسلسلة زمنية
Playing Cards	٢٠٨	بطاقات لعب
Polonium	٥٣٨	البولونيوم (مادة مشعة)
Raw Data	١٢	بيانات خام
Quantitative Data	٩	بيانات كمية
Grouped Data	٢٤	بيانات مجمعة (بيانات مُجدولة)
Qualitative Data	٦	بيانات نوعية
ت		
Permutations	٦٤٥	تباديل
Variance	٨٥	التباين
Empirical Variance	٨٦	التباين العملي (أو تباين العينة)
Variance of Sample	٤٥٢	تباين العينة
Finite Permutation	٦٤٥	تبديل منته
Random Experiment	١٨٨	تجارب عشوائية
Regular Experiment	١٨٧	تجارب نظامية
Bernoulli Experiment	٣٠٤	تجربة برنولية
Geiger–Marsden experiment	٣	تجربة جايجر ومارسدين
Trivial Partition	٢٠٣	التجزئة المبتذلة
The Generated Partition by RV	٣٩٩	التجزئة المولدة من متغير عشوائي
Partition of a Set	٢٠٣	تجزئة مجموعة
Analysis to Factors	٤٦٩	التحليل إلى عوامل
Fourier Translation	٣٩٣	تحويل فورييه
Classification of Samples	٤٤١	تصنيف العينات
Measurable Map	٦٥٥	تطبيق قيوس (أو قابل للقياس)
Tally	٣١	التعداد (تعداد عناصر فئة في جدول تكراري)
Classical Definition of Probability	٢٠٧	التعريف التقليدي للاحتمال
Geometric Definition of Probability	٢١٠	التعريف الهندسي للاحتمال
Covariance	١٢٢	التغاير
Total Variation	١٦٠	التغير الكلي
Explained Variation	١٦٠	التغير المُفسر
Unexplained Variation	١٦٠	التغير غير المُفسر
Seasonal Changes	٦٠٤	التغيرات الموسمية
Converges with probability equal to one	٤١٢	التقارب باحتمال يساوي الواحد
Converges in probability	٤١٢	التقارب بالاحتمال
Converges in Distribution	٤١٢	التقارب بالتوزيع

Converges in p-mean	٤١٢	التقارب بالمتوسط p
Convergence in Square Mean	٤١٢	التقارب بالمتوسط التربيعي
Converges Almost Sure	٤١٢	التقارب تقريباً أكيد (أو شبه أكيد)
Point Estimation	٤٨٥	التقدير بنقطة (أو التقدير النقطي)
Satterthwaite's Approximation	٤٦٣	تقريب ستيرثوايت
Almost Sure	٢٣٧	تقريباً أكيد
Integral of a Measurable Function	٦٦١	تكامل دالة قيوسة
Frequency	١٣	تكرار الفئات (عدد العناصر في فئة)
Frequency of Class	٢٤	تكرار الفئة
Ascending Cumulative Frequency	٣٢	التكرار المتجمع الصاعد
Descending Cumulative Frequency	٣٢	التكرار المتجمع الهابط
Absolut Frequency	٢٠٥	التكرار المطلق
Percent Frequency	٣٢	التكرار المئوي
Relative Frequency	٣١	التكرار النسبي
Expected Frequencies	٥٤٩	التكرارات المتوقعة
Representation by Picture	٢٣	التمثيل بالصور (الطريقة التصويرية)
Pie Chart	٢١	تمثيل للبيانات بقرص دائري
Dots Representation	١٦	تمثيل نقطي
Spline	٢١	التمهيد الشرائحي
Forecasting	٦١١	التنبؤ
Holt-Winters Smoothing	٦٠٩	التنعيم بطريقة هولت-وينتر
Smoothing of Time Series	٦٠١	تنعيم متسلسلات زمنية
Combinations	٦٤٥	توافيق
Discrete Probability Distribution	٣٠١	توزيع احتمالي متقطع
Continuous Probability Distribution	٣٢٣	توزيع احتمالي مستمر
Exponential Distribution	٣٢٤	التوزيع الأسّي
Binomial Distribution	٢٨٢	التوزيع الحداني
Negative Binomial Distribution	٣١١	التوزيع الحداني السالب
Normal (or Gaussian) Distribution	٣٢٧	التوزيع الطبيعي (أو التوزيع الغاوسي)
Degenerate Distribution	٣٠١	التوزيع المضمحل
Discrete Uniform Distribution	٣٠٧	التوزيع المنتظم المتقطع
Continuous Uniform Distribution	٣٢٣	التوزيع المنتظم المستمر
Geometric Distribution	٣١٤	التوزيع الهندسي
Bernoulli Distribution	٣٠٣	توزيع برنولي
Poisson Distribution	٢٨٢	توزيع بواسون
Non Symmetric Distributions	٤٩	توزيع تكراري غير متناظر

Symmetric Frequency Distribution	٤٨	توزيع تكراري متناظر
Skewed Frequency Distribution	٤٩	توزيع تكراري ملتوي
Tow Point Distribution	٣٠٣	التوزيع ثنائي النقطة
Compound Binomial Distribution	٢٨٢	توزيع حداني مُركَّب
Negative Skewed Distribution	٥٠	توزيع سالب الالتواء
Student Distribution (or t-Distribution)	٣٣٥	توزيع ستودنت (أو توزيع t)
Conditional Distribution	٢٧٣	توزيع شرطي
Hypergeometric Distribution	٣١٨	التوزيع فوق الهندسي (أو الفوهندسي)
Fisher distribution	٣٤٠	توزيع فيشر
Chi Square Distribution	٣٣٨	توزيع كاي مربع
Cauchy Distribution	٣٣٦	توزيع كوشي
Unimodal Symmetric Distribution	٤٨	توزيع متناظر أحادي المنوال
Multimodal Symmetric Distribution	٤٩	توزيع متناظر متعدّد المنوال
Leptokurtic Distribution	٤٨	توزيع مدبب
Compound Distribution	٢٨١	توزيع مركَّب
Mesokurtic Distribution	٤٨	توزيع معتدل
Skewed to the Left Distribution	٥٠	توزيع ملتوي نحو اليسار
Skewed to the Right Distribution	٤٩	توزيع ملتوي نحو اليمين
Platykurtic Distribution	٤٨	توزيع منبسط
Positive Skewed Distribution	٤٩	توزيع موجب الالتواء
Marginal Distribution	٢٧٨	توزيع هامشي
Weibull Distribution	٥٤٢	توزيع وايبول
One Point Distribution	٣٠١	التوزيع وحيد النقطة
Sampling Distributions	٤٥٦	توزيعات المعاينة
Nets Distribution	٤٣٤	توزيعات شبكية
Curves Fitting	١٤٣	توفيق المنحنيات
Fitting a Model of a Time Series	٦٠٩	توفيق نموذج متسلسلة زمنية
Mathematical Expectation	٣٥٩	التوقع الرياضي
Conditional Expectation	٣٩٨	التوقع الشرطي
ج		
Algebra	١٩٥	جبر
Algebra of Events	١٩٥	جبر الحوادث
Trivial Algebra	٢٠٢	الجبر المبثّل
Algebra of Finite Complements	٢٠١	جبر المتممات المنتهية
Pool algebra	١٩٨	جبر بول
σ -algebra	١٩٩	جبر من نوع σ (σ -جبر)

Joint Frequency Table	١٢٣	الجدول التكراري المشترك
Stem and Leafs Table	١٤	جدول الساق والأوراق
Frequency Table	١٣	جدول تكراري
Classes Table	٢٤	جدول تكراري ذو فئات
Frequency Distribution Table	٣٠	جدول توزيع تكراري
ح		
Elementary Event	١٩٥	حدث ابتدائي
Certain Event	١٩٦	الحدث الأكيد
Impossible Event	١٩٦	الحدث المستحيل
Simple Event	١٩٦	حدث بسيط
Atomic Event	١٩٥	حدث ذري
Almost Certainly Event	٢١٤	حدث شبه أكيد
Almost Impossible Event	٢١٠	حدث شبه مستحيل
Size of Sample	٣	حجم العينة
Size of Population	٢	حجم المجتمع
Highest Fence (HF)	٧٧	الحد الأدنى للقيم المتطرفة بكمبرها
Lowest Fence (LF)	٧٧	الحد الأعلى للقيم المتطرفة بصغرها
Lower Confidence Limit	٤٩٣	حد الثقة الأدنى
Upper Confidence Limit	٤٩٣	حد الثقة الأعلى
Class Boundaries	٢٧	الحدود العملية للفئة
Class Limit	٣٠	حدود الفئة
Borel Field	٦٥٣	حقل بوريلي
Martingale	٣٩٨	الحكمة
Mutually Exclusive Events	١٩٧	حوادث متنافية
Pairwise Mutually Exclusive Events	١٩٧	حوادث متنافية مثنى مثنى
Independent Events	٢٢٣	حوادث مستقلة
خ		
Consistency Property	٤٨٨	خاصية الاتساق
Regression Line	٤٠٤	خط انحدار
Curve	٢١	خط منحن
Error	١٤٥	خطأ
Standard Error	١٥٨	الخطأ المعياري
Standard Error of the Estimate	١٥٨	الخطأ المعياري للتقدير
Error of the First Type	٥١٥	الخطأ من النوع الأول
Error of the Second Type	٥١٥	الخطأ من النوع الثاني
Random Walk	٢٣١	الخطى العشوائية

د		
Likelihood Function	٤٨١	دالة الأرجحية
Projection Function	٢٦٦	دالة الإسقاط
Cumulative Distribution Function	٢٤٣	دالة التوزيع التراكمية
Empirical Distribution Function	٤٥٣	دالة التوزيع العملية
Marginal Distribution Function	٢٧٩	دالة التوزيع الهامشية
Probability Mass Function	٢٥٣	دالة الكتلة الاحتمالية
Marginal Density Function	٢٧٨	دالة الكثافة الهامشية
Radon Nikodym Density Function	٢٥٨	دالة الكثافة ل رادون- نيكوديم
Indicator Function	٦٤٦	الدالة المميزة
Indicator Function of an Event	٢٣٩	الدالة المميزة لحادث
Characteristic Function of PD	٣٩٢	الدالة المميزة للتوزيعات الاحتمالية
Characteristic Function of RV	٣٩٣	الدالة المميزة لمتغير عشوائي
Indicator Function of a Set	٦٤٦	الدالة المميزة لمجموعة
Logistic Function	٥٨٤	الدالة المنطقية
Probability Generating Function	٣٨٣	الدالة المولدة الاحتمالية
Moment Generating Function	٣٨٩	الدالة المولدة للعزوم
Growth Function	٥٨٣	دالة النمو
Simple Function	٦٤٧	دالة بسيطة
Beta Function	٦٤٩	دالة بيتا
Step Function	٦٤٧	دالة درجية
Sample Function	٤٥١	دالة عينة
Gama Function	٦٤٨	دالة غاما
Measurable Function	٦٥٥	دالة قيوسة (أو قابلة للقياس)
Convex Function	٦٤٧	دالة محدبة
Concave Function	٦٤٧	دالة مقعرة
Degree	٢٢	درجة (تستخدم لقياس الزوايا)
τ -Score	٩٥	الدرجة المعيارية τ (الدرجة المعيارية الثانية)
z -Score	٩٤	الدرجة المعيارية z
Standard Score	٩٣	درجة معيارية
Accuracy of Estimate	١٥٨	دقة التقدير
Base Period	٦١٥	دورة الأساس
Current Period	٦١٦	الدورة الحالية (أو الدورة الجارية)
Compare Period	٦٠٦	دورة المقارنة
Seasonal Cycle	٥٧٣	الدورة الموسمية
Previous Cycle	٦١١	دورة سابقة

Irregular Cyclical	٥٧٠	دورية غير منتظمة (عشوائية)
ذ		
Atom of the Partition	٢٠٣	ذرة تجزئة
ر		
Anscombe's Quartet	١٣٢	رباعية إنسكومب
Quartile (Quartiles)	٧٣	ربيعي (ربيعيات)
First Quartile (or Lower Quartile Q_1)	٧٣	الربيعي الأول (أو الربيعي الأدنى)
Third Quartile (or Upper Quartile Q_3)	٧٣	الربيعي الثالث (أو الربيعي الأعلى)
Second Quartile	٧٣	الربيعي الثاني
Rank	٧٤	رتبة
Order of the Partial Correlation	١٧٨	رتبة الارتباط الجزئي
Index Number	٦١٨	رقم قياسي
Simple Index Number	٦١٨	رقم قياسي بسيط
Simple Aggregate Index Number	٦٢٣	رقم قياسي كلي بسيط
Weighted Index Numbers	٦٢٥	رقم قياسي موزون
Composite Index Number	٦٢٣	رقماً قياسياً مركباً
س		
Pulling without Replacement	١٩٣	السحب بدون إرجاع
Draw without Replacement	٤٤٠	السحب بدون إرجاع (أو بدون إعادة)
Draw with Replacement	٤٤٠	السحب مع الإرجاع (أو مع الإعادة)
Pulling with Replacement	١٩٢	السحب مع الإرجاع
Angular Frequency	٥٩٢	السرعة الزاوية للاهتزاز
Default Class width	٢٨	السعة الافتراضية (لفئة في جدول تكراري)
Length of Class	٢٤	سعة الفئة (في جدول تكراري)
ش		
Markov Condition	٤٨٨	شرط ماركوف
Tail	١٩٠	شعار (في تجربة قذف قطعة نقود معدنية)
Whiskers	١٠٨	الشُعيرتان (شُعيرتا التمثيل الصندوقي للبيانات)
ص		
Monotone class	٦٥٤	صف مطّرد
Head	٤	صورة (يقابلها الكتابة على قطع النقود المعدنية)
Total Probability Formula	٢٢٠	صيغة الاحتمال التام
Steiner Formula	٣٧٤	صيغة شتاينر
ض		
White Noise	٥٧٠	الضجيج الأبيض

ط		
Methods of Sampling	٤٤٠	طرائق سحب العينة
Maximum Likelihood Method	٤٧٨	طريقة الأرجحية العظمى
Halberg's Cosine Method	٥٩١	طريقة التجيب ل هالبرغ
Tables Method	١٣	طريقة الجداول
Moments Method	٤٧٨	طريقة العزوم
Successive Differences Method	٥٧٨	طريقة الفروق المتتالية
Least Square Method	١٤٤	طريقة المربعات الصغرى
Ratio to Moving-Average Method	٦٠٥	طريقة النسبة إلى متوسط متحرك
Winters' Method	٦٠٠	طريقة وينتر
Winter's Method for Generate Forecasts	٦٠٨	طريقة وينتر لتوليد التنبؤات
White Noise Process	٥٧٠	طوري ضجيج أبيض
Random Process	٥٦٤	طوري عشوائي
Real Random Process	٥٦٤	طوري عشوائي حقيقي
Point Process	٢٣٨	طوري نقطي
Length of Period	٥٩٢	طول الدور
ع		
Default Number	٢٨	العدد الافتراضي (لفئات جدول تكراري)
Number of Classes	٣٠	عدد الفئات
Box plot	١٠٧	العرض (أو التمثيل) الصندوقي
Graphing of Data	١١	عرض البيانات
Bar Graph	١٧	العرض الشرائطي
The k th Factorial Moment	٣٧٦	العزم العامل من المرتبة k
Centered Moment	٣٧٢	العزم المركزي
Central Moment of Order r	٩٦	العزم المركزي من المرتبة r
Factorial Moment	٣٧٥	العزوم العامل (أو الضربي)
Moments of random variable	٣٥٨	العزوم لمتغير عشوائي
Central Moment	٩٦	عزوم مركزي
Causal Chain Relation	١١٧	علاقة السلسلة السببية
Reciprocal Relation	١١٧	علاقة تبادلية
Unidirectional Relation	١١٦	علاقة وحيد الاتجاه
Spurious Relation	١١٧	علاقة وهمية
Statistics	١	علم الإحصاء
Stochastic	١٨٨	علم العشوانيات
Initial Element	٤٤٥	عنصر البدء
Random Element	٢٣٨	عنصر عشوائي

Intentional Samples	٤٤١	عَيِّنَات عمدِيَّة (أو قَصْدِيَّة)
Selected Sample	٤٤٧	عَيِّنَات منتقاة
Sample	٢	عَيِّنَة
Systematic Sample	٤٤٥	العَيِّنَة الرتِيبِيَّة (أو المنتظمة)
Simple Random Sample	٤٤٤	العَيِّنَة العشوائية البسيطة
Quota Sample	٤٧٧	عَيِّنَة حصص (مبنية على المحاصصة)
Stratified Sample	٤٤٥	عَيِّنَة طبقية
Random Sample	٤٤١	عَيِّنَة عشوائية
Cluster Sample	٤٤٦	عَيِّنَة عنقودية
High-Size Sample	٤٤٧	عَيِّنَة كبيرة الحجم
غ		
Uncountable Set	٦٤٢	غير قابلة للعدّ
Uncorrelated	٣٦٨	غير مرتبطين
ف		
Confidence Interval	٤٩٢	فترة ثقة
Lag	٥٦٤	فجوة زمنية
Statistical hypothesis	٥١٣	فرضية إحصائية
Null Hypothesis	٥١٤	الفرضية الابتدائية (أو الفرضية الصفرية)
Alternative Hypothesis	٥١٤	الفرضية البديلة
Simple hypothesis	٥١٨	فرضية بسيطة
Composite hypothesis	٥١٨	فرضية مركبة
Acrophase	٥٩٢	فرق الصفحة
Separable	٢٣٨	فصول (أو قابل للفصل)
Probability Space	١٨٧	فضاء احتمالي
Space of Elementary Events	١٩٥	فضاء الحوادث الابتدائية
Measure Space	٦٥٦	فضاء قياس
Metric Space	٦٥٣	فضاء متري
Measurable Space	٢١٤	فضاء مقيس
Class (Group, Category or Interval)	٢٤	الفئة (في الجداول التكرارية)
ق		
Countable Set	٦٤٢	قابلة للعدّ
Integrablity of a Real Function	٦٦١	قابلية المكاملة لدالّة حقيقية
Additive Rule	٦٤٦	قاعدة الجمع
Multiplication Rule	٦٤٦	قاعدة الضرب
Chebyshev Empirical Rule	٨٩	قاعدة تشببشيف التجريبية
Addition Law	٢١٥	قانون الجمع

Multiplication Law of Probability	٢٢٠	قانون الضرب في الاحتمالات
Weak Law of Large Numbers	٤١٤	القانون الضعيف للأعداد الكبيرة
Strong Law of Large Numbers	٤١٤	القانون القوي للأعداد الكبيرة
Bernoulli's Law of Large Numbers	٤١٦	قانون برنولي للأعداد الكبيرة
Poisson's Law of Large Numbers	٤١٦	قانون بواسون للأعداد الكبيرة
Distribution Law	٢٤٠	قانون توزيع
Cardinality of a Set	٦٤٢	قدرة مجموعة
Coin	١٩٠	قطعة نقود معدنية
Laws of Large Numbers	٤١٤	قوانين الأعداد الكبيرة
Power of the Test	٥١٥	قوة الاختبار (أو حساسية الاختبار)
Ogive	٤٣	القوس القوطي
Measure	٦٥٦	قياس
σ -Finite Measure	٦٥٧	قياس σ - منته
Probability Measure	١٨٩	قياس احتمالي
Measuring Fitting Accuracy	٦١١	قياس جودة التوفيق
Dirac Measure	٢١٥	قياس ديراك
Lebesgue Measure	٦٥٧	قياس لوبيغ
Finite Measure	٦٥٧	قياس منته
Observation Values	٤٤٩	قيم ملحوظة (أو مشاهدة)
Critical Value	٥١٦	قيمة حرجة
Extreme Value	٧٧	قيمة متطرفة
Predicted Value	١٤٦	قيمة مقدرة
Outlier Value	٧٧	قيمة منعزلة
Fitted Value	١٤٦	قيمة موفقة (تم توفيقها من منحنى التوفيق)
Relative Value	٦١٨	قيمة نسبية
ك		
Probability Mass	٢٥٣	كتلة احتمالية
Relative Efficiency	٤٨٩	الكفاءة النسبية
Integrable	٢٥٩	كمول (أو قابل للمكاملة)
Fisher's Information Quantity	٤٧١	كمية معلومات فيشر
ل		
Scatter Plot	١١٩	لوحة الانتشار
م		
Pauli Principle	١٩٤	مبدأ باولي (مبدأ الاستبعاد)
Fisher -Neumann Proposition	٤٦٨	مبرهنة فيشر - نويمان
Chebyshev Inequality	٣٨١	متباينة تشيبشيف

Jensen inequality	٣٦٣	متباينة جينسين
Rao-Cramer Inequality	٤٩٠	متباينة راو- كرامر
Cauchy – Schwartz inequality	٣٦٤	متباينة كوشي- شفارتز
Cauchy–Schwartz Inequality	٣٦٤	متباينة كوشي- شفارتز
Lyapunov Inequality	٣٧١	متباينة ليابانوف
Markov inequality	٣٧١	متباينة ماركوف
Essentially Sequence	٤١٣	متتالية أساسية
Cauchy Sequence	٤١٣	متتالية كوشي
Random Vector	٢٣٨	متجه عشوائي
Discrete Random Vector	٢٧٢	متجه عشوائي متقطع
Mixed Random Vector	٢٧٤	متجه عشوائي مختلط
Continuous Random Vectors	٢٧٣	متجه عشوائي مستمر
Time Series	٥٦٣	متسلسلة زمنية
Variable	٥	متغير
Response Variable	١١٥	متغير الاستجابة
Dependent Variable	١١٥	المتغير التابع
Predictor Variable	١٤٦	المتغير المتنبأ به
Explanatory Variable	١١٥	متغير تفسيري
Random Variable	٢٣٣	متغير عشوائي
Bernoulli Random Variable	٣٠٤	متغير عشوائي برنولي
Complex Random Variable	٢٣٨	متغير عشوائي عقدي
Discrete Random Variable	٢٥٢	متغير عشوائي متقطع
Continuous Random Variable	٢٥٨	متغير عشوائي مستمر
Normalized random variable	٣٧٥	متغير عشوائي مستنظم
Regular Random variable	٤٧١	متغير عشوائي نظامي
Quantitative Variable	٧	متغير كمي
Discrete Variable	٦	متغير متقطع
Continuous Variable	٦	متغير مستمر
Confusing Variable	١٧٨	متغير مشوش
Perturbation Variable	١٧٨	متغير مشوش
Independent Random Variables	٣٥١	متغيرات عشوائية مستقلة
Independent Variables	٣٥١	متغيرات مستقلة
Qualitative Variables	٧	متغيرات نوعية
Discrete	٤	متقطع (أو منفصل)
Complement of an Event	١٩٦	متكم حدث
Mean (or Arithmetic Mean)	٥٦	المتوسط (أو المتوسط الحسابي)

Harmonic Mean	٦٤	المتوسط التوافقي
Trimmed mean (TrMean)	٧٢	المتوسط الحسابي المشتب
Mean of Sample	٤٥٢	متوسط العينة
Mean Absolute Deviation (MAD)	٦١١	متوسط القيم المطلقة للانحرافات
Mean Absolute Percentage Error (MAPE)	٦١١	متوسط القيم المطلقة للنسب المنوية للأخطاء
Weighted Mean	٦١	المتوسط الموزون
Geometric Mean	٦٢	المتوسط الهندسي
Weighted Geometric Mean	٦٣	المتوسط الهندسي الموزون
Moving Average	٦٠٢	متوسط متحرك
Mean Square Deviation (MSD)	٦١١	متوسط مربع الانحرافات
Mean Squared Error	١٦٠	متوسط مربع الخطأ
The Risk of Type II	٥١٥	المجازفة من النوع الثاني
Population	١	مجتمع إحصائي
Independent Populations	٤٦١	مجتمعات مستقلة
Borel Set	٢١٤	مجموعة بوريلية
Compact Set	٢٣٩	مجموعة متراسة
Convex Set	٦٤٤	مجموعة محدبة
Continuous Set	٤	مجموعة مستمرة (أو متصلة)
Random Closed Set	٢٣٩	مجموعة مغلقة عشوائية
Set of Outcomes	١٨٩	مجموعة نتائج
Bertrand Paradox	٢١١	مُحيرة برتراند
Leptokurtic	٤٨	مُدبب
Relative Frequency Histogram	٣٧	مدرج التكراري النسبي
Frequency Histogram	٣٦	مدرج تكراري
Percentile Frequency Histogram	٣٨	مدرج تكراري منوي
Range	٢٧	المدى
Interquartile Range (IQR)	٩١	المدى الربيعي
Trend Component	٥٦٩	مركبة الاتجاه العام
Random Error Component	١٥٥	مركبة الخطأ العشوائي
Period (or Cyclical) Component	٥٧٠	المركبة الدورية
Seasonal Component	٥٦٩	المركبة الموسمية
Systematic Component	١٥٥	المركبة النظامية (أو الرتيبة)
Irregular Component	٥٧٠	مركبة عشوائية (أو غير منتظمة)
Midpoint	٣١	مركز الفنة (في جدول تكراري)
Gnedenko Problem	٤٣٤	مسألة غنيدينكو
Lyapunov Problem	٤٢٨	مسألة لياباتوف

Lindenberg – Feller Problem	٤٣١	مسألة ليندنبيرغ – فيلر
Lindenberg – Levy Problem	٤٢١	مسألة ليندنبيرغ – ليفي
Moivre – Laplace Problem	٤١٧	مسألة موافير – لابلاس
Independent	٢٢٣	مستقل
Statistical Independent	٢٢٤	مستقلة إحصائياً
Stochastic Independent	٢٢٤	مستقلة عشوائياً
Pairwise Independent	٢٢٤	مستقلة مثنى مثنى
Straight Regression	١٤٥	مستقيم الانحدار
Absolutely Continuous	٢٥٨	مستمر مطلقاً
Level	٦٠٩	المستوى (أو التمهيد)
Confidence Level	٤٩٣	مستوى الثقة (أو معامل الثقة)
Significance Level	٥١٥	مستوى أهمية
Significance Level of the Test	٥١٥	مستوى أهمية الاختبار
Comprehensive Survey	٢	المسح الشامل
Covariance Matrix	١٢٥	مصفوفة التباين
Polygon	١٩	مضلع (تمثيل بقطع مستقيمة متتالية)
Ascending Cumulative Frequency Paragon (Less than Origin)	٤٢	مضلع التكرار المتجمع الصاعد (أقل من قوسل قوطي)
Descending Cumulative Frequency Polygon (Less than Origin)	٤٢	مضلع التكرار المتجمع الهابط (أقل من قوس قوطي)
Frequency Polygon	٤١	مضلع تكراري
Cumulative Frequency Paragon	٤٢	مضلعات تكراري تراكمي
Amplitude	٥٩٢	مطال
Regression Equation	٤٠٤	معادلة انحدار
Welch–Satterthwaite Equation	٤٦٣	معادلة ويلش ستيرثوايت
Partial Correlation Coefficient	١٧٨	معامل الارتباط الجزئي
Coefficient of Association	١٤٠	معامل الاقتران
Moment Coefficient of Skewness	١٠٠	معامل الالتواء العزومي
Coefficient of Determination	١٣٩	معامل التحديد
Coefficient of Dispersion	٩٣	معامل التشتت
Coefficient of Variation	٩٢	معامل التغير
Coefficient of Contingency	١٤١	معامل التوافق
Roughness Coefficient	٦٠١	معامل الخشونة
Bowley's Coefficient of Skewness	١٠٢	معامل بولي للالتواء
Person's Coefficient of Correlation	١٢٧	معامل بيرسون للارتباط
Person's Coefficient of Skewness	١٠٠	معامل بيرسون للالتواء
Person's Coefficient of Kurtosis	١٠٦	معامل بيرسون للتفلطح
Spearman Rho Correlation Coefficient	١٣١	معامل سبيرمان رو للارتباط

Spearman’s Rank Correlation Coefficient	١٣٠	مُعامل سبيرمان لارتباط الرتب
Regression Coefficients	١٤٦	مُعاملات (أو وسطاء) الانحدار
Correlation Coefficients	١٢١	مُعاملات الارتباط
Simple Average	٦١٩	المعدل البسيط
Parameter	٥٦	مُعْذمة (أو وسيط)
Trend Parameter	٦١٠	مُعْذمة الاتجاه العام
Seasonal Parameter	٦١٠	مُعْذمة الموسمي
Population Parameter	٤٧٧	مُعْذمة مجتمع إحصائي
Perturbation Parameter	٥١٨	مُعْذمة مشوشة
Asymptotically Normal Distributed	٤١٩	مقارب للتوزيع الطبيعي
Resistance	٤	مقاومة أوميّة
Descriptive Measures	٥٥	مقاييس وصفية
Unbiasedness Quantity	٤٨٦	مقدار التحيز
Statistical Estimator	٤٧٨	مقدّر إحصائي
Maximum Likelihood Estimator	٤٨١	مقدّر الأرجحية العظمى
Highest Efficient Estimator	٤٨٩	المقدّر الأعلى كفاءة
Estimator more efficient from another	٤٨٩	المقدّر الأكفأ من مُقدّر آخر
Pooled Estimator of Variance	٤٦٣	المقدّر المشترك للتباين
Unbiased Estimator	٤٨٦	المقدّر المُنصف (أو غير المنحاز)
Efficient Estimator	٤٨٩	مقدّر كفوء
Consistent Estimator	٤٨٨	مقدّر متنسق
Asymptotic Unbiased Estimator	١٨٧	مقدّر منصف تقاربياً
Nominal Scale	٧	مقياس اسمي
Variability Measure	٨٣	مقياس الاختلاف (تسمية أخرى لمقياس التشتت)
Spread Measures	٨٣	مقياس الانتشار (تسمية أخرى لمقياس التشتت)
Scatter Measure	٨٣	مقياس التبعثر (تسمية أخرى لمقياس التشتت)
Skewness Measure	٩٩	مقياس التواء
Form Measures	٩٦	مقياس الشكل
Interval Scale	٩	مقياس الفترة
Ration Scale	٩	مقياس النسبة
Ordinal Scale	٨	مقياس ترتيبي
Dispersion Measure	٨٢	مقياس تشتت
Kurtosis Measure	١٠٥	مقياس تفلطح (أو تفرطح)
Position Measure	٥٥	مقياس موضع
Central Tendency Measure	٥٦	مقياس نزعة مركزيّة
Observation	٣	ملحوظة (أو مشاهدة)

Frequency Curve	٤٣	منحنى تكراري
Unbiasedness	٤٨٦	منصف أو غير متحيز
Critical Region of the Test	٥١٥	المنطقة الحرجة للاختبار
Rejection Area	٥١٥	منطقة الرفض
Optimum Rejection Area	٥١٩	منطقة الرفض المثلى
Acceptance Area	٥١٥	منطقة القبول
Critical Region	٥١٥	منطقة حرجة
Mode	٧٠	المنوال
Positive Definite	٣٩٤	موجبة التعيين
Fisher's ideal index	٦٣١	المؤشر المثالي ل فيشر
Paasche index	٦٢٥	مؤشر باشي
Laspeyres Index	٦٢٥	مؤشر لسبيريس
Percentile (Percentiles)	٧٧	منين (المنينات)
r-Percentile (or r th Percentile)	٧٧	المنين الراني
ن		
Outcome	١٨٩	نتيجة (نتيجة تجربة)
Taylor's Expansion	٣٩٠	نشر تايلور
Stirling Expansion	٦٤٥	نشر سترلنغ
Subadditive	٦٥٧	نصف جمعي
σ -Finite	٦٥٧	نصف جمعي σ - منته (أو نصف جمعي عدود)
Finite Subadditive	٦٥٧	نصف جمعي منته
Continuity theorem's	٣٩٢	نظريات الاستمرار
Convolution theorem's	٣٩٢	نظريات التلاف
Inversion theorems	٣٩٢	نظريات العكس
Central limit theorem's	٤١١	نظريات النهاية المركزية
Uniqueness theorem's	٣٩٢	نظريات الوحدانية
Decision-Making Theory	٥١٣	نظرية اتخاذ القرار
Probability Theory	١٨٨	نظرية الاحتمالات
Estimation Theory	٤٧٧	نظرية التقدير
Martingale Theorem	٣٩٨	نظرية الحكمة
Queuing theory	٣٢٠	نظرية الطوابير
Measure Theory	١٥٩	نظرية القياس
Sampling Theory	٣	نظرية المعاينة
Local Central Limit Theorem	٤٣٤	نظرية النهاية المركزية الموضعية
Reliability Theory	٣٢٠	نظرية الوثوقية
Bochner Theorem	٣٩٦	نظرية بوخنر

Beppo – Levi's Theorem	٦٦٢	نظرية بيبو – ليفي
Bays's theorem	٢٢١	نظرية بيبز
Radon–Nikodym Theorem	٦٣٣	نظرية رادون – نيكوديم
Gnedenko Theorem	٤٣٤	نظرية غندينكو
Fubini Theorem	٦٦٢	نظرية فوبيني
Lyapunov Theorem	٤٢٨	نظرية لياباتوف
Lévy Theorem	٣٩٧	نظرية ليفي
Lindenberg – Feller Theorem	٤٣١	نظرية ليندنبيرغ – فيلر
Lindenberg–Levy Theorem	٤٢٢	نظرية ليندنبيرغ – ليفي
Neyman Pearson Theorem	٥١٩	نظرية نيمان – بيرسون
Critical Point	٥١٦	نقطة حرجة
Harmonic Model	٥٧٠	نموذج (أو نمط) توافقي
Additive Model	٥٧٢	نموذج الجمع
Multiplicative Model	٥٧٢	نموذج الضرب
Smoothing Model	٥٧٢	نموذج تنعيم
Theoretical Mathematical Model	٤٥٠	نموذج رياضياتي نظري
Random Kern	٢٣٩	نواة عشوائية
هـ		
Stochastic Geometry	٢١٣	الهندسة العشوائية
و		
Fahrenheit	١٠	وحدة الفهرنهايت لقياس الحرارة
Kelvin	١٠	وحدة الكلفين لقياس الحرارة المنخفضة جداً
Sampling Unit	٤٣٩	وحدة المعاينة
Celsius	١٠	وحدة لقياس الحرارة (الدرجة المئوية)
Monetary Units	٦١٩	وحدة نقدية
Weight for the Trend	٦٠٩	الوزن من أجل الاتجاه العام
Weight for the seasonal component	٦٠٩	الوزن من أجل المركبة الموسمية
Weight for the level	٦٠٩	الوزن من أجل المستوى (أو من أجل التمهيد)
Median	٦٦	وسيط (أو الوسط)
ي		
Equal Almost Every Where	٦٦٢	يساوي تقريباً في كل مكان

English ⇒ عربي

A		
Absolut Frequency	٢٠٥	التكرار المطلق
Absolute Continuation	٦٦٣	الاستمرار المطلق
Absolutely Continuous	٢٥٨	مستمر مطلقاً
Acceptance Area	٥١٥	منطقة القبول
Accuracy of Estimate	١٥٨	دقة التقدير
Acrophase	٥٩٢	فرق الصفحة
Addition Law	٢١٥	قانون الجمع
Additive Model	٥٧٢	نموذج الجمع
Additive Rule	٦٤٦	قاعدة الجمع
Algebra	١٩٥	جبر
Algebra of Events	١٩٥	جبر الحوادث
Algebra of Finite Complements	٢٠١	جبر المتممات المنتهية
Almost Certainly Event	٢١٤	حادث شبه أكيد
Almost Impossible Event	٢١٠	حادث شبه مستحيل
Almost Sure	٢٣٧	تقريباً أكيد
Alternative Hypothesis	٥١٤	الفرضية البديلة
Amplitude	٥٩٢	مطال
Analysis to Factors	٤٦٩	التحليل إلى عوامل
Anderson-Darling Test for Goodness of Fit	٥٤٢	اختبار أندرسون-دارلينغ لجودة التوفيق
Angular Frequency	٥٩٢	السرعة الزاوية للاهتزاز
Anscombe's Quartet	١٣٢	رباعية إنسكومب
Ascending Cumulative Frequency	٣٢	التكرار المتجمع الصاعد
Ascending Cumulative Frequency Paragon (Less than Ogive)	٤٢	مضلع التكرار المتجمع الصاعد (أقل من قوسلقوطي)
Asymptotic Unbiased Estimator	١٨٧	مقدر منصف تقاربياً
Asymptotically Normal Distributed	٤١٩	مقارب للتوزيع الطبيعي
Atom of the Partition	٢٠٣	ذرة تجزئة
Atomic Event	١٩٥	حادث ذري
Autoregressive Integrated Moving Average (ARIMA)	٦٠٤	الانحدار الذاتي والمتوسطات المتحركة المتكاملة
B		
Bar Graph	١٧	العرض الشرائطي
Base Period	٦١٥	دورة الأساس
Bays's theorem	٢٢١	نظرية بيبز

Beppo – Levi's Theorem	٦٦٢	نظرية بيبو – ليفي
Bernoulli Distribution	٣٠٣	توزيع برنولي
Bernoulli Experiment	٣٠٤	تجربة برنولية
Bernoulli Random Variable	٣٠٤	متغير عشوائي برنولي
Bernoulli's Law of Large Numbers	٤١٦	قانون برنولي للأعداد الكبيرة
Bertrand Paradox	٢١١	مُحيرة برتراند
Best Test	٥١٩	أفضل اختبار
Beta Function	٦٤٩	دالة بيتا
Binomial Distribution	٢٨٢	التوزيع الحداني
Bochner Theorem	٣٩٦	نظرية بوخنر
Borel Field	٦٥٣	حقل بوريلي
Borel Set	٢١٤	مجموعة بوريلية
Bose – Einstein Statistic	١٩٤	إحصاءة بوزي – أينشتاين
Bowley's Coefficient of Skewness	١٠٢	معامل بولي للالتواء
Box plot	١٠٧	العرض (أو التمثيل) الصندوقي
C		
Cardinality of a Set	٦٤٢	قدرة مجموعة
Cauchy – Schwartz inequality	٣٦٤	متباينة كوشي – شفارتز
Cauchy Distribution	٣٣٦	توزيع كوشي
Cauchy Sequence	٤١٣	متتالية كوشي
Cauchy–Schwartz Inequality	٣٦٤	متباينة كوشي – شفارتز
Causal Chain Relation	١١٧	علاقة السلسلة السببية
Causal Correlation	١١٧	الارتباط السببي
Celsius	١٠	وحدة لقياس الحرارة (الدرجة المنوية)
Centered Moment	٣٧٢	العزم المركزي
Central limit theorem's	٤١١	نظريات النهاية المركزية
Central Moment	٩٦	عزم مركزي
Central Moment of Order r	٩٦	العزم المركزي من المرتبة r
Central Tendency Measure	٥٦	مقياس نزعة مركزيّة
Certain Event	١٩٦	الحادث الأكيد
Characteristic Function of PD	٣٩٢	الدالة المميزة للتوزيعات الاحتمالية
Characteristic Function of RV	٣٩٣	الدالة المميزة لمتغير عشوائي
Chebyshev Inequality	٣٨١	متباينة تشببيشيف
Chebyshev Empirical Rule	٨٩	قاعدة تشببيشيف التجريبية
Chi Square Distribution	٣٣٨	توزيع كاي مربع
Chi-Squared Test for Goodness of Fit	٣٣٧	اختبار كاي مربع لجودة التوفيق

الفئة (في الجداول التكرارية)	٢٤	Class (Group, Category or Interval)
الحدود العملية للفئة	٢٧	Class Boundaries
حدود الفئة	٣٠	Class Limit
جدول تكراري ذو فئات	٢٤	Classes Table
التعريف التقليدي للاحتمال	٢٠٧	Classical Definition of Probability
تصنيف العينات	٤٤١	Classification of Samples
عينة عنقودية	٤٤٦	Cluster Sample
معامل الاقتران	١٤٠	Coefficient of Association
معامل التوافق	١٤١	Coefficient of Contingency
معامل التحديد	١٣٩	Coefficient of Determination
معامل التشتت	٩٣	Coefficient of Dispersion
معامل التغير	٩٢	Coefficient of Variation
قطعة نقود معدنية	١٩٠	Coin
توافيق	٦٤٥	Combinations
مجموعة متراسة	٢٣٩	Compact Set
دورة المقارنة	٦٠٦	Compare Period
متعم حادث	١٩٦	Complement of an Event
متغير عشوائي عقدي	٢٣٨	Complex Random Variable
فرضية مركبة	٥١٨	Composite hypothesis
رقماً قياسياً مركباً	٦٢٣	Composite Index Number
توزيع حداني مركب	٢٨٢	Compound Binomial Distribution
توزيع مركب	٢٨١	Compound Distribution
المسح الشامل	٢	Comprehensive Survey
دالة مقعرة	٦٤٧	Concave Function
توزيع شرطي	٢٧٣	Conditional Distribution
التوقع الشرطي	٣٩٨	Conditional Expectation
احتمال شرطي	٢١٨	Conditional Probability
فترة ثقة	٤٩٢	Confidence Interval
مستوى الثقة (أو معامل الثقة)	٤٩٣	Confidence Level
متغير مشوش	١٧٨	Confusing Variable
خاصية الاتساق	٤٨٨	Consistency Property
مقدر منسق	٤٨٨	Consistent Estimator
نظريات الاستمرار	٣٩٢	Continuity theorem's
الاستمرار من الأعلى	٢١٥	Continuous from Above
الاستمرار من الأدنى	٢١٥	Continuous from Below
توزيع احتمالي مستمر	٣٢٣	Continuous Probability Distribution

Continuous Random Variable	٢٥٨	متغير عشوائي مستمر
Continuous Random Vectors	٢٧٣	متجه عشوائي مستمر
Continuous Set	٤	مجموعة مستمرة (أو متصلة)
Continuous Uniform Distribution	٣٢٣	التوزيع المنتظم المستمر
Continuous Variable	٦	متغير مستمر
Convergence in Square Mean	٤١٢	التقارب بالمتوسط التربيعي
Converges Almost Sure	٤١٢	التقارب تقريباً أكيد (أو شبه أكيد)
Converges in Distribution	٤١٢	التقارب بالتوزيع
Converges in p-mean	٤١٢	التقارب بالمتوسط p
Converges in probability	٤١٢	التقارب بالاحتمال
Converges with probability equal to one	٤١٢	التقارب باحتمال يساوي الواحد
Convex Function	٦٤٧	دالة محدبة
Convex Set	٦٤٤	مجموعة محدبة
Convolution theorem's	٣٩٢	نظريات التلاف
Correlation Coefficients	١٢١	معاملات الارتباط
Countable Set	٦٤٢	قابلة للعد
Covariance	١٢٢	التغاير
Covariance Matrix	١٢٥	مصفوفة التغاير
Critical Point	٥١٦	نقطة حرجة
Critical Region	٥١٥	منطقة حرجة
Critical Region of the Test	٥١٥	المنطقة الحرجة للاختبار
Critical Value	٥١٦	قيمة حرجة
Cumulative Distribution Function	٢٤٣	دالة التوزيع التراكمية
Cumulative Frequency Paragon	٤٢	مضامع تكراري تراكمي
Current Period	٦١٦	الدورة الحالية (أو الدورة الجارية)
Curve	٢١	خط منحن
Curves Fitting	١٤٣	توفيق المنحنيات
D		
Decision-Making Theory	٥١٣	نظرية اتخاذ القرار
Default Class width	٢٨	السعة الافتراضية (لفئة في جدول تكراري)
Default Number	٢٨	العدد الافتراضي (لفئات جدول تكراري)
Degenerate Distribution	٣٠١	التوزيع المضمحل
Degree	٢٢	درجة (تستخدم لقياس الزوايا)
Dependent Variable	١١٥	المتغير التابع
Descending Cumulative Frequency	٣٢	التكرار المتجمع الهابط

Descending Cumulative Frequency Polygon (Less than Ogive)	٤٢	مضلع التكرار المتجمع الهابط (أقل من قوس قوطني)
Descriptive Measures	٥٥	مقاييس وصفية
Dirac Measure	٢١٥	قياس ديراك
Discrete	٤	متقطع (أو منفصل)
Discrete Probability Distribution	٣٠١	توزيع احتمالي متقطع
Discrete Random Variable	٢٥٢	متغير عشوائي متقطع
Discrete Random Vector	٢٧٢	متجه عشوائي متقطع
Discrete Uniform Distribution	٣٠٧	التوزيع المنتظم المتقطع
Discrete Variable	٦	متغير متقطع
Dispersion Measure	٨٢	مقياس تشتت
Distribution Law	٢٤٠	قانون توزيع
Dots Representation	١٦	تمثيل نقطي
Draw with Replacement	٤٤٠	السحب مع الإرجاع (أو مع الإعادة)
Draw without Replacement	٤٤٠	السحب بدون إرجاع (أو بدون إعادة)
E		
Efficient Estimator	٤٨٩	مقدر كفوء
Elementary Event	١٩٥	حادث ابتدائي
Empirical Distribution Function	٤٥٣	دالة التوزيع العملية
Empirical Variance	٨٦	التباين العملي (أو تباين العينة)
Equal Almost Every Where	٦٦٢	يساوي تقريباً في كل مكان
Error	١٤٥	خطأ
Error of the First Type	٥١٥	الخطأ من النوع الأول
Error of the Second Type	٥١٥	الخطأ من النوع الثاني
Essentially Sequence	٤١٣	متتالية أساسية
Estimation Theory	٤٧٧	نظرية التقدير
Estimator more efficient from another	٤٨٩	المقدر الأكفأ من مقدر آخر
Expected Frequencies	٥٤٩	التكرارات المتوقعة
Explained Variation	١٦٠	التغير المفسر
Explanatory Variable	١١٥	متغير تفسيري
Exponential Distribution	٣٢٤	التوزيع الأسّي
Exponential Regression	١٦٨	الانحدار الأسّي
Extreme Value	٧٧	قيمة متطرفة
F		
Factorial Moment	٣٧٥	العزوم العاملية (أو الضربية)
Fahrenheit	١٠	وحدة الفهرنهايت لقياس الحرارة

Failure Probability	٣٠٤	احتمال الفشل
Fermi-Dirac Statistic	١٩٤	إحصاءة فيرمي – ديراك
Finite Measure	٦٥٧	قياس منته
Finite Permutation	٦٤٥	تبديل منته
Finite Subadditive	٦٥٧	نصف جمعي منته
First Quartile (or Lower Quartile Q_1)	٧٣	الربيعي الأول (أو الربيعي الأدنى)
Fisher distribution	٣٤٠	توزيع فيشر
Fisher -Neumann Proposition	٤٦٨	مبرهنة فيشر– نويمان
Fisher’s ideal index	٦٣١	المؤشر المثالي ل فيشر
Fisher's Information Quantity	٤٧١	كمية معلومات فيشر
Fitted Value	١٤٦	قيمة موفقة (تم توفيقها من منحنى التوفيق)
Fitting a Model of a Time Series	٦٠٩	توفيق نموذج متسلسلة زمنية
Five Number and the Box plot	١٠٧	الأعداد الخمسة والتمثيل الصندوقي للبيانات
Forecasting	٦١١	التنبؤ
Form Measures	٩٦	مقياس الشكل
Fourier Translation	٣٩٣	تحويل فورييه
Framework	٤٣٩	الإطار (إطار العمل)
Frequency	١٣	تكرار الفئات (عدد العناصر في فئة)
Frequency Curve	٤٣	منحنى تكراري
Frequency Distribution Table	٣٠	جدول توزيع تكراري
Frequency Histogram	٣٦	مدرج تكراري
Frequency of Class	٢٤	تكرار الفئة
Frequency Polygon	٤١	مضلع تكراري
Frequency Table	١٣	جدول تكراري
Fubini Theorem	٦٦٢	نظرية فوبيني
G		
Gama Function	٦٤٨	دالة غاما
Geiger–Marsden experiment	٣	تجربة جايجر ومارسیدن
Geometric Definition of Probability	٢١٠	التعريف الهندسي للاحتمال
Geometric Distribution	٣١٤	التوزيع الهندسي
Geometric Mean	٦٢	المتوسط الهندسي
Gnedenko Problem	٤٣٤	مسألة غنيدينكو
Gnedenko Theorem	٤٣٤	نظرية غنيدينكو
Goodness of Distribution Fit Test	٥٣٧	اختبار جودة توفيق توزيع احتمالي
Graphing of Data	١١	عرض البيانات
Grouped Data	٢٤	بيانات مجمعة (بيانات مجدولة)

Growth Function	٥٨٣	دالة النمو
H		
Halberg's Cosine Method	٥٩١	طريقة التجيب ل هالبرغ
Harmonic Mean	٦٤	المتوسط التوافقي
Harmonic Model	٥٧٠	نموذج (أو نمط) توافقي
Head	٤	صورة (يقابلها الكتابة على قطع النقود المعدنية)
Highest Efficient Estimator	٤٨٩	المقدر الأعلى كفاءة
Highest Fence (HF)	٧٧	الحد الأدنى للقيم المتطرفة بكبرها
High-Size Sample	٤٤٧	عينة كبيرة الحجم
Holt-Winters Smoothing	٦٠٩	التنعيم بطريقة هولت-وينتر
Homogeneity Test of Distribution	٥٤٤	اختبار التجانس لتوزيع احتمالي
Hypergeometric Distribution	٣١٨	التوزيع فوق الهندسي (أو الفوهندسي)
I		
Impossible Event	١٩٦	الحادث المستحيل
Imprint of Time Series	٥٦٥	بصمة متسلسلة زمنية
Independence of Events	٢٢٣	استقلال حوادث
Independence Test of two Phenomenon	٥٤٨	اختبار استقلال ظاهرتين
Independent	٢٢٣	مستقل
Independent Events	٢٢٣	حوادث مستقلة
Independent Populations	٤٦١	مجتمعات مستقلة
Independence of Random Variables	٣٥١	استقلال المتغيرات العشوائية
Independent Random Variables	٣٥١	متغيرات عشوائية مستقلة
Independent Variables	٣٥١	متغيرات مستقلة
Index Number	٦١٨	رقم قياسي
Indicator Function	٦٤٦	الدالة المميزة
Indicator Function of a Set	٦٤٦	الدالة المميزة لمجموعة
Indicator Function of an Event	٢٣٩	الدالة المميزة لحدث
Initial Element	٤٤٥	عنصر البدء
Integrable	٢٥٩	كمول (أو قابل للمكاملة)
Integrablity of a Real Function	٦٦١	قابلية المكاملة لدالة حقيقية
Integral of a Measurable Function	٦٦١	تكامل دالة قيوسة
Intentional Samples	٤٤١	عينات عمدية (أو قصدية)
Interquartile Range (IQR)	٩١	المدى الربيعي
Interval Scale	٩	مقياس الفترة
Inversion theorems	٣٩٢	نظريات العكس
Irregular Component	٥٧٠	مركبة عشوائية (أو غير منتظمة)

Irregular Cyclical	٥٧٠	دورية غير منتظمة (عشوائية)
J		
Jensen inequality	٣٦٣	متباينة جينسين
Joint Frequency Table	١٢٣	الجدول التكراري المشترك
K		
Kelvin	١٠	وحدة الكلفين لقياس الحرارة المنخفضة جداً
Kolmogorov-Smirnov Test	٥٣٩	اختبار كلموغوراف – سميرنوف
Kurtosis Measure	١٠٥	مقياس تفلطح (أو تفرطح)
L		
Lag	٥٦٤	فجوة زمنية
Laspeyres Index	٦٢٥	مؤشر لسبيريس
Laws of Large Numbers	٤١٤	قوانين الأعداد الكبيرة
Least Square Method	١٤٤	طريقة المربعات الصغرى
Lebesgue Measure	٦٥٧	قياس لوبيغ
Length of Class	٢٤	سعة الفئة (في جدول تكراري)
Length of Period	٥٩٢	طول الدور
Leptokurtic	٤٨	مُدبب
Leptokurtic Distribution	٤٨	توزيع مدبب
Level	٦٠٩	المستوى (أو التمهيد)
Lévy Theorem	٣٩٧	نظرية ليفي
Likelihood Function	٤٨١	دالة الأرجحية
Lindenberg – Feller Problem	٤٣١	مسألة ليندنبرغ – فيلر
Lindenberg – Feller Theorem	٤٣١	نظرية ليندنبرغ – فيلر
Lindenberg – Levy Problem	٤٢١	مسألة ليندنبرغ – ليفي
Lindenberg–Levy Theorem	٤٢٢	نظرية ليندنبرغ– ليفي
Local Central Limit Theorem	٤٣٤	نظرية النهاية المركزية الموضعية
Logarithmic Regression	١٦٧	الانحدار اللوغاريتمي
Logistic Function	٥٨٤	الدالة المنطقية
Lower Confidence Limit	٤٩٣	حد الثقة الأدنى
Lower Continuity of a measure	٦٥٨	الاستمرار من الأدنى لقياس
Lowest Fence (LF)	٧٧	الحد الأعلى للقيم المتطرفة بصغرها
Lyapunov Inequality	٣٧١	متباينة لياباتوف
Lyapunov Problem	٤٢٨	مسألة لياباتوف
Lyapunov Theorem	٤٢٨	نظرية لياباتوف
M		
Marginal Density Function	٢٧٨	دالة الكثافة الهامشية

Marginal Distribution	٢٧٨	توزيع هامشي
Marginal Distribution Function	٢٧٩	دالة التوزيع الهامشية
Markov Condition	٤٨٨	شرط ماركوف
Markov inequality	٣٧١	متباينة ماركوف
Martingale	٣٩٨	الحكمة
Martingale Theorem	٣٩٨	نظرية الحكمة
Mathematical Expectation	٣٥٩	التوقع الرياضي
Mathematical Statistics	١٨٨	الإحصاء الرياضي
Maximum Likelihood Estimator	٤٨١	مقدر الأرجحية العظمى
Maximum Likelihood Method	٤٧٨	طريقة الأرجحية العظمى
Maxwell–Boltzmann Statistic	١٩٤	إحصاءة ماكسويل–بولتسمان
Mean (or Arithmetic Mean)	٥٦	المتوسط (أو المتوسط الحسابي)
Mean Absolute Deviation (MAD)	٦١١	متوسط القيم المطلقة للانحرافات
Mean Absolute Percentage Error (MAPE)	٦١١	متوسط القيم المطلقة للنسب المنوية للأخطاء
Mean of Sample	٤٥٢	متوسط العينة
Mean Square Deviation (MSD)	٦١١	متوسط مربع الانحرافات
Mean Squared Error	١٦٠	متوسط مربع الخطأ
Mean Deviation (or Average Deviations)	٨٣	الانحراف المتوسط (أو متوسط الانحرافات)
Measurable Function	٦٥٥	دالة قيوسة (أو قابلة للقياس)
Measurable Map	٦٥٥	تطبيق قيوس (أو قابل للقياس)
Measurable Space	٢١٤	فضاء مقيس
Measure	٦٥٦	قياس
Measure Space	٦٥٦	فضاء قياس
Measure Theory	١٥٩	نظرية القياس
Measuring Fitting Accuracy	٦١١	قياس جودة التوفيق
Median	٦٦	وسيط (أو الوسط)
Mesokurtic Distribution	٤٨	توزيع معتدل
Methods of Sampling	٤٤٠	طرائق سحب العينة
Metric Space	٦٥٣	فضاء متري
Midpoint	٣١	مركز الفنة (في جدول تكراري)
Mixed Random Vector	٢٧٤	متجه عشوائي مختلط
Mode	٧٠	المنوال
Moivre – Laplace Problem	٤١٧	مسألة موافير–لابلاس
Moment Coefficient of Skewness	١٠٠	معامل الالتواء العزومي
Moment Generating Function	٣٨٩	الدالة المولدة للعزوم
Moments Method	٤٧٨	طريقة العزوم

Moments of random variable	٣٥٨	العزوم لمتغير عشوائي
Monetary Units	٦١٩	وحدة نقدية
Monotone class	٦٥٤	صف مطرد
Monotony	٦٥٧	الاطراد
Moving Average	٦٠٢	متوسط متحرك
Multimodal Symmetric Distribution	٤٩	توزيع متناظر متعدد المنوال
Multiple Correlation	١١٧	الارتباط المتعدد
Multiplication Law of Probability	٢٢٠	قانون الضرب في الاحتمالات
Multiplication Rule	٦٤٦	قاعدة الضرب
Multiplicative Model	٥٧٢	نموذج الضرب
Mutually Exclusive Events	١٩٧	حوادث متنافية
N		
Negative Binomial Distribution	٣١١	التوزيع الحداني السالب
Negative Skewed Distribution	٥٠	توزيع سالب الالتواء
Nets Distribution	٤٣٤	توزيعات شبكية
Neumann Deference Test	٥٨٧	اختبار الفرق لـ نويمان
Neyman Pearson Theorem	٥١٩	نظرية نيمان – بيرسون
Nominal Scale	٧	مقياس اسمي
Non Linear Correlation	١١٨	الارتباط غير الخطي
Non Parametric Test	513	اختبار غير معلمي
Non Symmetric Distributions	٤٩	توزيع تكراري غير متناظر
Normal (or Gaussian) Distribution	٣٢٧	التوزيع الطبيعي (أو التوزيع الغاوسي)
Normalized random variable	٣٧٥	متغير عشوائي مستنظم
Null Hypothesis	٥١٤	الفرضية الابتدائية (أو الفرضية الصفرية)
Number of Classes	٣٠	عدد الفئات
O		
Observation	٣	ملحوظة (أو مشاهدة)
Observation Values	٤٤٩	قيم ملحوظة (أو مشاهدة)
Ogive	٤٣	القوس القوطي
One Point Distribution	٣٠١	التوزيع وحيد النقطة
One -Tailed Test	٥١٨	اختبار أحادي الطرف (أو أحادي الذيل)
Optimal Test	٥٢٠	الاختبار الأمثل
Optimum Rejection Area	٥١٩	منطقة الرفض المثلى
Order of the Partial Correlation	١٧٨	رتبة الارتباط الجزئي
Ordinal Scale	٨	مقياس ترتيبي
Outcome	١٨٩	نتيجة (نتيجة تجربة)

Outlier Value	٧٧	قيمة منعزلة
P		
Paasche index	٦٢٥	مؤشر باشي
Pairwise Independent	٢٢٤	مستقلة مثنى مثنى
Pairwise Mutually Exclusive Events	١٩٧	حوادث متنافية مثنى مثنى
Parameter	٥٦	مَعْلَمَة (أو وسيط)
Parametric Test	٥١٣	اختبار مَعْلَمِي
Partial Correlation	١١٧	الارتباط الجزئي
Partial Correlation Coefficient	١٧٨	مُعامل الارتباط الجزئي
Partition of a Set	٢٠٣	تجزئة مجموعة
Pauli Principle	١٩٤	مبدأ باولي (مبدأ الاستبعاد)
Percent Frequency	٣٢	التكرار المئوي
Percentile (Percentiles)	٧٧	مئين (المئينات)
Percentile Frequency Histogram	٣٨	مدرج تكراري مئوي
Period (or Cyclical) Component	٥٧٠	المركبة الدورية
Permutation	٦٤٥	تباديل
Person's Coefficient of Correlation	١٢٧	مُعامل بيرسون للارتباط
Person's Coefficient of Kurtosis	١٠٦	مُعامل بيرسون للتفلطح
Person's Coefficient of Skewness	١٠٠	مُعامل بيرسون للالتواء
Perturbation Parameter	٥١٨	مَعْلَمَة مشوشة
Perturbation Variable	١٧٨	متغير مشوش
Pie Chart	٢١	تمثيل للبيانات بقرص دائري
Platykurtic Distribution	٤٨	توزيع منبسط
Playing Cards	٢٠٨	بطاقات لعب
Point Estimation	٤٨٥	التقدير بنقطة (أو التقدير النقطي)
Point Process	٢٣٨	طوري نقطي
Poisson Distribution	٢٨٢	توزيع بواسون
Poisson's Law of Large Numbers	٤١٦	قانون بواسون للأعداد الكبيرة
Polonium	٥٣٨	البولونيوم (مادة مشعة)
Polygon	١٩	مضلع (تمثيل بقطع مستقيمة متتالية)
Pool algebra	١٩٨	جبر بول
Pooled Estimator of Variance	٤٦٣	المقدر المشترك للتباين
Population	١	مجتمع إحصائي
Population Parameter	٤٧٧	مَعْلَمَة مجتمع إحصائي
Position Measure	٥٥	مقياس موضع
Positive Definite	٣٩٤	موجبة التعيين

Positive Skewed Distribution	٤٩	توزيع موجب الالتواء
Power of the Test	٥١٥	قوة الاختبار (أو حساسية الاختبار)
Power Regression	١٦٩	انحدار القوى
Predicted Value	١٤٦	قيمة مقدرة
Predictor Variable	١٤٦	المتغير المتنبأ به
Previous Cycle	٦١١	دورة سابقة
Prior Probability	٢٢١	الاحتمال الأسبق
Probability Generating Function	٣٨٣	الدالة المولدة الاحتمالية
Probability Mass	٢٥٣	كتلة احتمالية
Probability Mass Function	٢٥٣	دالة الكتلة الاحتمالية
Probability Measure	١٨٩	قياس احتمالي
Probability Space	١٨٧	فضاء احتمالي
Probability Theory	١٨٨	نظرية الاحتمالات
Projection Function	٢٦٦	دالة الإسقاط
Pulling with Replacement	١٩٢	السحب مع الإرجاع
Pulling without Replacement	١٩٣	السحب بدون إرجاع
Q		
Qualitative Data	٦	بيانات نوعية
Qualitative Variables	٧	متغيرات نوعية
Quantitative Data	٩	بيانات كمية
Quantitative Variable	٧	متغير كمي
Quartile (Quartiles)	٧٣	ربيعي (ربيعيات)
Queuing theory	٣٢٠	نظرية الطوابير
Quota Sample	٤٧٧	عينة حصص (مبنية على المحاصصة)
R		
Radon Nikodym Density Function	٢٥٨	دالة الكثافة ل رادون- نيكوديم
Radon–Nikodym Theorem	٦٣٣	نظرية رادون – نيكوديم
Random Closed Set	٢٣٩	مجموعة مغلقة عشوائية
Random Element	٢٣٨	عنصر عشوائي
Random Error Component	١٥٥	مركبة الخطأ العشوائي
Random Experiment	١٨٨	تجارب عشوائية
Random Kern	٢٣٩	نواة عشوائية
Random Process	٥٦٤	طوري عشوائي
Random Sample	٤٤١	عينة عشوائية
Random Variable	٢٣٣	متغير عشوائي
Random Vector	٢٣٨	متجه عشوائي

الخطى العشوائية	٢٣١	Random Walk
المدى	٢٧	Range
رتبة	٧٤	Rank
متباينة راو- كرامر	٤٩٠	Rao-Cramer Inequality
طريقة النسبة إلى متوسط متحرك	٦٠٥	Ratio to Moving-Average Method
مقياس النسبة	٩	Ration Scale
بيانات خام	١٢	Raw Data
طوري عشوائي حقيقي	٥٦٤	Real Random Process
الارتباط التبادلي	١١٧	Reciprocal Correlation
علاقة تبادلية	١١٧	Reciprocal Relation
مُعاملات (أو وسطاء) الانحدار	١٤٦	Regression Coefficients
معادلة انحدار	٤٠٤	Regression Equation
خط انحدار	٤٠٤	Regression Line
تجارب نظامية	١٨٧	Regular Experiment
متغير عشوائي نظامي	٤٧١	Regular Random variable
منطقة الرفض	٥١٥	Rejection Area
الكفاءة النسبية	٤٨٩	Relative Efficiency
التكرار النسبي	٣١	Relative Frequency
مدرج التكراري النسبي	٣٧	Relative Frequency Histogram
الانحراف المعياري النسبي	٩٣	Relative Standard Deviation
قيمة نسبية	٦١٨	Relative Value
نظرية الوثوقية	٣٢٠	Reliability Theory
التمثيل بالصور (الطريقة التصويرية)	٢٣	Representation by Picture
الباقى	١٤٥	Residual
مقاومة أومية	٤	Resistance
متغير الاستجابة	١١٥	Response Variable
أغنى جبر (أو أقوى جبر)	٢٠٢	Richest Algebra (or Strongest Algebra)
معامل الخشونة	٦٠١	Roughness Coefficient
المنين الراني	٧٧	r-Percentile (or r th Percentile)
S		
عينة	٢	Sample
دالة عينة	٤٥١	Sample Function
توزيعات المعاينة	٤٥٦	Sampling Distributions
نظرية المعاينة	٣	Sampling Theory
وحدة المعاينة	٤٣٩	Sampling Unit
تقريب ستيرثوايت	٤٦٣	Satterthwaite’s Approximation

Scatter Measure	٨٣	مقياس التبعثر(تسمية أخرى لمقياس التشتت)
Scatter Plot	١١٩	لوحة الانتشار
Seasonal Changes	٦٠٤	التغيرات الموسمية
Seasonal Component	٥٦٩	المركبة الموسمية
Seasonal Cycle	٥٧٣	الدورة الموسمية
Seasonal Parameter	٦١٠	معطمة الموسمي
Second Quartile	٧٣	الربيعي الثاني
Selected Sample	٤٤٧	عينات منتقاة
Separable	٢٣٨	فصول (أو قابل للفصل)
Set of Outcomes	١٨٩	مجموعة نتائج
Significance Level	٥١٥	مستوى أهمية
Significance Level of the Test	٥١٥	مستوى أهمية الاختبار
Simple Aggregate Index Number	٦٢٣	رقم قياسي كلي بسيط
Simple Average	٦١٩	المعدل البسيط
Simple Correlation	١١٧	الارتباط البسيط
Simple Event	١٩٦	حادث بسيط
Simple Fractional Regression	١٦٧	الانحدار الكسري البسيط
Simple Function	٦٤٧	دالة بسيطة
Simple hypothesis	٥١٨	فرضية بسيطة
Simple Index Number	٦١٨	رقم قياسي بسيط
Simple Linear Correlation	١١٥	الارتباط الخطي البسيط
Simple Random Sample	٤٤٤	العينة العشوائية البسيطة
Size of Population	٢	حجم المجتمع
Size of Sample	٣	حجم العينة
Skewed Frequency Distribution	٤٩	توزيع تكراري ملتوي
Skewed to the Left Distribution	٥٠	توزيع ملتوي نحو اليسار
Skewed to the Right Distribution	٤٩	توزيع ملتوي نحو اليمين
Skewness Measure	٩٩	مقياس التواء
Smoothing Model	٥٧٢	نموذج تنعيم
Smoothing of Time Series	٦٠١	تنعيم متسلسلات زمنية
Space of Elementary Events	١٩٥	فضاء الحوادث الابتدائية
Spearman Rho Correlation Coefficient	١٣١	معامل سبيرمان رو للارتباط
Spearman’s Rank Correlation Coefficient	١٣٠	معامل سبيرمان لارتباط الرتب
Spline	٢١	التمهيد الشرائحي
Spread Measures	٨٣	مقياس الانتشار(تسمية أخرى لمقياس التشتت)
Spurious Correlation	١١٧	الارتباط الوهمي

Spurious Relation	١١٧	علاقة وهمية
Standard Deviation	٨٧	الانحراف المعياري
Standard Error	١٥٨	الخطأ المعياري
Standard Error of the Estimate	١٥٨	الخطأ المعياري للتقدير
Standard Score	٩٣	درجة معيارية
Standardization	٩٥	استيعار أو استقياس (أي جعله معيارياً أو قياسياً)
Statistic	٤٥١	إحصاءة
Statistical Estimator	٤٧٨	مقدر إحصائي
Statistical hypothesis	٥١٣	فرضية إحصائية
Statistical Hypothesis test	٥١٣	اختبار فرضية إحصائية
Statistical Independent	٢٢٤	مستقلة إحصائياً
Statistical Inference	٤٧٧	الاستدلال الإحصائي
Staurt-Cox Test	٦٨٨	اختبار سترأوت-كوكس
Statistics	١	علم الإحصاء
Steiner Formula	٣٧٤	صيغة شتاينر
Stem and Leafs Table	١٤	جدول الساق والأوراق
Step Function	٦٤٧	دالة درجية
Stirling Expansion	٦٤٥	نشر سترلنغ
Stochastic	١٨٨	علم العشوانيات
Stochastic Geometry	٢١٣	الهندسة العشوانية
Stochastic Independent	٢٢٤	مستقلة عشوانياً
Straight Regression	١٤٥	مستقيم الانحدار
Stratified Sample	٤٤٥	عينة طبقية
Strong Law of Large Numbers	٤١٤	القانون القوي للأعداد الكبيرة
Student Distribution (or t-Distribution)	٣٣٥	توزيع ستودنت (أو توزيع t)
Subadditive	٦٥٧	نصف جمعي
Success Probability	٣٠٤	احتمال النجاح
Successive Differences Method	٥٧٨	طريقة الفروق المتتالية
Sufficiency Statistic	٤٦٧	الإحصاءة الكافية
Superior Probability	٢٢١	الاحتمال اللاحق
Symmetric Frequency Distribution	٤٨	توزيع تكراري متناظر
Systematic Component	١٥٥	المركبة النظامية (أو الرتيبة)
Systematic Sample	٤٤٥	العينة الرتيبة (أو المنتظمة)
Systematic Vibrations	٥٦٩	اهتزازات رتيبة
T		
Tables Method	١٣	طريقة الجداول

Tail	١٩٠	شعار (في تجربة قذف قطعة نقود معدنية)
Tally	٣١	التعداد (تعداد عناصر فئة في جدول تكراري)
Taylor's Expansion	٣٩٠	نشر تايلور
The Generated Partition by RV	٣٩٩	التجزئة المولدة من متغير عشوائي
The k th Factorial Moment	٣٧٦	العزم العامل من المرتبة k
The Risk of Type II	٥١٥	المجازفة من النوع الثاني
Theoretical Mathematical Model	٤٥٠	نموذج رياضياتي نظري
Third Quartile (or Upper Quartile Q ₃)	٧٣	الربيعي الثالث (أو الربيعي الأعلى)
Time Series	٥٦٣	متسلسلة زمنية
Total Probability Formula	٢٢٠	صيغة الاحتمال التام
Total Variation	١٦٠	التغير الكلي
Trend	٥٦٩	الاتجاه العام
Trend Component	٥٦٩	مركبة الاتجاه العام
Trend Parameter	٦١٠	معطاة الاتجاه العام
Trimmed mean (TrMean)	٧٢	المتوسط الحسابي المشتب
Trivial Algebra	٢٠٢	الجبر المبذل
Trivial Partition	٢٠٣	التجزئة المبذلة
τ-Score	٩٥	الدرجة المعيارية -ح (الدرجة المعيارية الثانية)
Tow Point Distribution	٣٠٣	التوزيع ثنائي النقطة
Two-Tailed Test	٥١٨	اختبار ثنائي الطرف (أو ثنائي الذيل)
U		
Unbiased Estimator	٤٨٦	المقدر المُنصف (أو غير المنحاز)
Unbiasedness	٤٨٦	منصف أو غير متحيز
Unbiasedness Quantity	٤٨٦	مقدار التحيز
Uncorrelated	٣٦٨	غير مرتبطين
Uncountable Set	٦٤٢	غير قابلة للعد
Unexplained Variation	١٦٠	التغير غير المُفسر
Unidirectional Relation	١١٦	علاقة وحيد الاتجاه
Unimodal Symmetric Distribution	٤٨	توزيع متناظر أحادي المنوال
Uniqueness theorem's	٣٩٢	نظريات الوحدةانية
Upper Confidence Limit	٤٩٣	حد الثقة الأعلى
Upper Continuity	٦٥٨	الاستمرار من الأعلى
V		
Variability Measure	٨٣	مقياس الاختلاف (تسمية أخرى لمقياس التشتت)
Variable	٥	متغير
Variance	٨٥	التباين

Variance of Sample	٤٥٢	تباين العينة
W		
Wallis –Moore Test	٥٨٨	اختبار الفروق الأولى ل ووليس- مور
Weak Law of Large Numbers	٤١٤	القانون الضعيف للأعداد الكبيرة
Weibull Distribution	٥٤٢	توزيع وايبول
Weight for the level	٦٠٩	الوزن من أجل المستوى (أو من أجل التمهيد)
Weight for the seasonal component	٦٠٩	الوزن من أجل المركبة الموسمية
Weight for the Trend	٦٠٩	الوزن من أجل الاتجاه العام
Weighted Geometric Mean	٦٣	المتوسط الهندسي الموزون
Weighted Index Numbers	٦٢٥	رقم قياسي موزون
Weighted Mean	٦١	المتوسط الموزون
Welch–Satterthwaite Equation	٤٦٣	معادلة ويلش ستيرثوايت
Whiskers	١٠٨	الشعيرتان (شعيرتا التمثيل الصندوقي للبيانات)
White Noise	٥٧٠	الضجيج الأبيض
White Noise Process	٥٧٠	طوري ضجيج أبيض
Winters’ Method	٦٠٠	طريقة وينتر
Winter's Method for Generate Forecasts	٦٠٨	طريقة وينتر لتوليد التنبؤات
Z		
z-Score	٩٤	الدرجة المعيارية -z
σ		
σ-Finite Measure	٦٥٧	قياس σ- منته
σ-algebra	١٩٩	جبر من نوع σ (σ- جبر)
σ-Finite	٦٥٧	نصف جمعي σ- منته (أو نصف جمعي عدود)